



TESIS - SS14 2501

Model Hybrid Vector Autoregressive-Support Vector Regression dan Generalized Space-Time Autoregressive-Support Vector Regression with Exogenous Variables untuk Peramalan Arus Uang di KPW II BI

BAHAGIATI MAGHFIROH
NRP. 06211650010022

DOSEN PEMBIMBING
Dr. Santi Puteri Rahayu, M.Si.
Dr. Suhartono, M.Sc.

PROGRAM MAGISTER
JURUSAN STATISTIKA
FAKULTAS MATEMATIKA, KOMPUTASI DAN SAINS DATA
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018



THESIS - SS14 2501

Hybrid Vector Autoregressive-Support Vector Regression and Generalized Space-Time Autoregressive-Support Vector Regression with Exogenous Variables for Forecasting Cashflow in KPW II BI

BAHAGIATI MAGHFIROH
NRP. 06211650010022

SUPERVISOR
Dr. Santi Puteri Rahayu, M.Si.
Dr. Suhartono, M.Sc.

MAGISTER PROGRAMME
DEPARTMENT OF STATISTICS
FACULTY OF MATHEMATICS, COMPUTING AND DATA SCIENCE
INSTITUT TEKNOLOGI SEPULUH NOPEMBER
SURABAYA
2018

**Model Hybrid Vector Autoregressive-Support Vector Regression
dan Generalized Space-Time Autoregressive-Support Vector
Regression with Exogenous Variables untuk Peramalan Arus Uang
di KPW II BI**


Tesis disusun untuk memenuhi salah satu syarat memperoleh gelar
Magister Sains (M.Si.)

di
Institut Teknologi Sepuluh Nopember
Oleh:

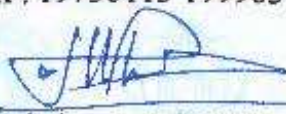
BAHAGIATI MAGHFIROH
NRP. 06211650010022

Tanggal Ujian : 16 Januari 2018
Periode Wisuda : September 2018


Disetujui Oleh:


1. Dr. Santi Puteri Rahayu, M.Si.
NIP. 19750115 199903 2 003

(Pembimbing I)


2. Dr. Suhartono, M.Sc.
NIP. 19710929 199512 1 001

(Pembimbing II)


3. Dr. rer. pol. Dedy Dwi P, M.Si.
NIP. 19831204 200812 1 002

(Penguji)

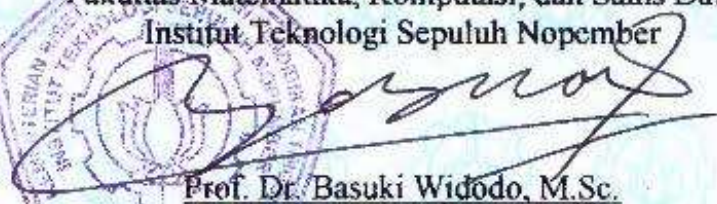

4. Irhamah, M.Si., Ph.D.
NIP. 19780406 200112 2 002

(Penguji)

Dekan

Fakultas Matematika, Komputasi, dan Sains Data
Institut Teknologi Sepuluh Nopember




Prof. Dr. Basuki Widodo, M.Sc.
NIP. 19650605 198903 1 002

**Model Hybrid Vector Autoregressive-Support Vector Regression
dan Generalized Space-Time Autoregressive-Support Vector
Regression with Exogenous Variables untuk Peramalan Arus Uang
di KPW II BI**

Nama Mahasiswa : Bahagiati Maghfiroh
NRP : 06211650010022
Pembimbing : Dr. Santi Puteri Rahayu, M.Si.
Dr. Suhartono, M.Sc.

ABSTRAK

Seiring dengan semakin banyaknya kajian mengenai analisis *time series*, muncul dugaan ada beberapa data yang tidak hanya mengandung keterkaitan dengan kejadian pada waktu-waktu sebelumnya, tetapi juga mempunyai keterkaitan dengan lokasi lain yang berdekatan (*neighbouring*). Salah satu model *time series* yang melibatkan aspek spasial (*spatio-temporal*) adalah *Generalized Space-Time Autoregressive* (GSTAR) yang merupakan perbaikan dari model STAR. Prediksi untuk data *time series* dibedakan menjadi dua pendekatan, yaitu linier dan non linier. Model *hybrid* menggabungkan model linier dan nonlinier, pada penelitian ini dilakukan *hybrid* VARX-SVR dan *hybrid* GSTARX-SVR untuk meramalkan *inflow* dan *outflow*. Kemudian memilih model terbaik dengan nilai RMSE *out sample* terkecil untuk selanjutnya digunakan dalam peramalan. Studi kasus dalam penelitian ini adalah *inflow* dan *outflow* di Kantor Perwakilan Wilayah Jawa Barat di tiga Kantor Bank Indonesia yaitu KBI Bandung, KBI Cirebon dan KBI Tasikmalaya. Hasil studi simulasi menunjukkan bahwa model GSTAR-GLS memberikan parameter yang lebih efisien dibandingkan dengan GSTAR-OLS. Model VARX-SVR merupakan model terbaik untuk simulasi residual non linier dan VARX merupakan model terbaik untuk simulasi residual linier. Pada studi terapan, model VARX merupakan model terbaik untuk data *outflow* di semua lokasi. Model terbaik untuk data *inflow* adalah VARX di KBI Bandung dan KBI Cirebon serta GSTARX-SVR untuk KBI Tasikmalaya dengan bobot seragam.

Kata Kunci: *Hybrid, VARX-SVR, GSTARX-SVR, GSTARX, Inflow, Outflow*

Hybrid Vector Autoregressive-Support Vector Regression and Generalized Space-Time Autoregressive-Support Vector Regression with Exogenous Variables for Forecasting Cashflow in KPW II BI

Name of Student : Bahagiati Maghfiroh
NRP : 06211650010022
Supervisor : Dr. Santi Puteri Rahayu, M.Si.
Dr. Suhartono, M.Sc.

ABSTRACT

Along with the increasing number of studies on time series analysis, it is thought that there are some data not only related to events at earlier times but also related to other locations. Time series model that involves the spatial (spatio-temporal) aspect is Generalized Space-Time Autoregressive (GSTAR) which is an improvement of the STAR model. The prediction for time series data is divided into two approaches, i.e a linear and nonlinear approach. The hybrid model works by combining linear and nonlinear models. In this study, hybrid VARX-SVR and hybrid GSTARX-SVR are used to predict the inflow and outflow. Then obtaining the best model with minimum RMSE value in out sample, that is used for forecasting. As a case study is an inflow and outflow at the Regional Representative Office of West Java in three Bank Indonesia offices namely KBI Bandung, KBI Cirebon and KBI Tasikmalaya. The simulation study show that the GSTARX-GLS model gives more efficient parameters than GSTARX-OLS. Hybrid VARX-SVR model is the best model for nonlinear residual and VARX is the best model for linear residual. In applied data, VARX model is the best model for outflow in all location. The best model for inflow is VARX in KBI Bandung and KBI Cirebon, GSTARX-SVR is the best model for KBI Tasikmalaya with uniform weight.

Keywords: Hybrid, VARX-SVR, GSTARX-SVR, GSTARX, Inflow, Outflow

KATA PENGANTAR

Syukur Alhamdulillah penulis panjatkan kehadiran Allah SWT, yang maha menguasai segala ilmu dan alam, atas rahmat, ridho dan hidayah-Nya sehingga pengerjaan serta penulisan Tesis dengan judul “**Model Hybrid Vector Autoregressive-Support Vector Regression dan Generalized Space-Time Autoregressive-Support Vector Regression with Exogenous Variables untuk Peramalan Arus Uang di KPW II BI**” dapat terselesaikan dengan baik.

Penulisan Tesis ini adalah salah satu syarat yang harus dipenuhi dalam memperoleh gelar Magister sesuai dengan kurikulum Departemen Statistika FMKSD-ITS Surabaya. Dalam penyelesaian Tesis serta laporan ini penulis tidak terlepas dari bantuan serta dukungan dari berbagai pihak. Oleh karena itu penulis ingin mengucapkan terima kasih sebesar-besarnya kepada:

1. Ibu Tisah, Bapak Kasnan, Kak Feris dan Hesti, Adik Iwan, Saka serta keluarga besar penulis atas segala doa, dukungan materi, motivasi, kepercayaan dan kasih sayang.
2. Bapak Dr. Suhartono, M.Sc. selaku Ketua Departemen Statistika ITS dan dosen pembimbing yang telah banyak memberikan bimbingan, saran, dan bantuan selama pengerjaan Tesis.
3. Ibu Dr. Santi Puteri Rahayu, M.Si selaku dosen pembimbing yang dengan sabar memberikan bimbingan, arahan, dan masukan selama pengerjaan Tesis.
4. Bapak Dr. rer.pol. Dedy Dwi P, M.Si dan Ibu Irhamah, M.Si, Ph.D selaku dosen penguji yang telah memberikan tambahan ilmu selama proses perbaikan laporan Tesis.
5. Bapak Drs. Agus Suharsono, MS selaku dosen wali yang telah membimbing dan mengarahkan sejak awal perkuliahan.
6. Bapak Dr. rer.pol. Heri Kuswanto, M.Si selaku Ketua Program Studi Pascasarjana Statistika ITS.
7. Seluruh dosen pengajar serta karyawan di departemen Statistika ITS, yang telah memberikan bantuan dan ilmunya sebagai bekal dalam pengerjaan Tesis.

8. Bapak drg. Hendrianto Trisnowibowo, MARS selaku ayah dan atasan selama di Badan Penelitian dan Pengembangan Kesehatan, Kementerian Kesehatan RI serta rekan-rekan atas doa, dukungan dan semangat.
9. Teman-teman S2 Statistika ITS angkatan 2016, khususnya teman seperjuangan Meranggi, Kak Reni, Kak Nana, Kak Fael dkk yang telah membantu dalam penyelesaian laporan.
10. Sahabat-sahabatku Via, Kak Silvi, Kak Rana, Zahri, Indah, Nia semoga persaudaraan kita tidak akan lekang oleh waktu.
11. Pihak-pihak lain yang telah mendukung dan membantu dalam penyusunan Tesis ini yang tidak mungkin penulis sebutkan satu per satu. Terima kasih.

Penulis menyadari bahwa penyusunan Tesis ini masih jauh dari sempurna, maka kritik dan saran yang membangun akan senantiasa penulis harapkan demi kesempurnaan di masa mendatang. Semoga laporan ini dapat memberikan sum-bangan yang bermanfaat bagi semua pihak.

Surabaya, Januari 2018

Penulis

DAFTAR ISI

HALAMAN JUDUL	iii
LEMBAR PENGESAHAN	Error! Bookmark not defined.
ABSTRAK	vii
ABSTRACT	ix
KATA PENGANTAR	xi
DAFTAR ISI	xiii
DAFTAR TABEL	xv
DAFTAR GAMBAR	xvii
DAFTAR LAMPIRAN	xxi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	8
1.3 Tujuan Penelitian	9
1.4 Manfaat Penelitian	9
1.5 Batasan Masalah	9
BAB 2 TINJAUAN PUSTAKA	11
2.1 Analisis <i>Multivariate Time Series</i>	11
2.1.1 <i>Matrix Cross Correlation Function</i> (MCCF)	11
2.1.2 <i>Matrix Partial Cross Correlation Function</i> (MPCCF)	13
2.2 Model <i>Vector Autoregressive Integrated Moving Average</i>	16
2.2.1 Estimasi Parameter Model VARIMA	17
2.2.2 Pemeriksaan Diagnostik Model VARIMA	18
2.2.3 Peramalan Model VARIMA	19
2.3 Model <i>Space-Time Autoregressive</i> (STAR)	20
2.4 Model <i>Generalized Space-time Auto regressive</i> (GSTAR)	21
2.4.1 Pemilihan Bobot Lokasi pada Model GSTAR	22
2.4.2 Estimasi Parameter Model GSTAR	25
2.4.3 Kondisi Stasioner Parameter Model GSTAR	32
2.5 Peramalan Model <i>Multivariate Time Series</i>	32

2.6 Model <i>Support Vector Machine</i>	33
2.6.1 <i>Support Vector Regression</i> (SVR)	35
2.7 Pemilihan Model Terbaik.....	40
2.8 Pengedaran Uang di Indonesia.....	41
BAB 3 METODOLOGI PENELITIAN	45
3.1 Sumber Data.....	45
3.2 Variabel Penelitian	46
3.3 Struktur Data	47
3.3.1 Data <i>Inflow</i>	47
3.3.2 Data <i>Outflow</i>	49
3.4 Metode Penelitian.....	50
3.4.1 Kajian Simulasi	50
3.4.2 Kajian Terapan	58
BAB 4 ANALISIS DAN PEMBAHASAN	69
4.1 Pemodelan Data Simulasi	69
4.1.1 Pemodelan Residual Linier (Skenario 1).....	70
4.1.2 Pemodelan Residual Non Linier (Skenario 2).....	85
4.1.3 Pemilihan Model Terbaik Data Simulasi	95
4.1.4 Peramalan <i>Out Sample</i> Model Dua Level	97
4.2 Pemodelan Data Terapan	98
4.2.1 Statistika Deskriptif.....	100
4.2.2 Pemodelan Data <i>Outflow</i> Bank Indonesia.....	102
4.2.3 Pemodelan Data <i>Inflow</i> Bank Indonesia	117
4.2.4 Pengujian Asumsi Residual Model VAR dan GSTAR	129
4.2.5 Pemilihan Model Terbaik Data Terapan	130
4.2.6 Peramalan <i>Out Sample</i> Model Dua Level	134
BAB 5 KESIMPULAN DAN SARAN	139
DAFTAR PUSTAKA	141
LAMPIRAN	149
BIODATA PENULIS	201

DAFTAR TABEL

Tabel 2.1 Contoh Nilai MCCF untuk Tiga Variabel <i>Time Series</i>	13
Tabel 2.2 Contoh Nilai MPCCF untuk Tiga Variabel <i>Time Series</i>	15
Tabel 3.1 Jarak Antar Lokasi di Tiga Lokasi di Jawa Barat	46
Tabel 3.2 Variabel Penelitian.....	46
Tabel 3.3 Variabel <i>Dummy</i> yang Digunakan	47
Tabel 3.4 Ketentuan Periode Mingguan.....	48
Tabel 3.5 Identifikasi Variabel <i>Dummy</i> selama Periode Pengamatan (<i>Inflow</i>)	48
Tabel 3.6 Struktur Data <i>Inflow</i> dengan Prediktor Variabel <i>Dummy</i>	49
Tabel 3.7 Identifikasi Variabel <i>Dummy</i> selama Periode Pengamatan (<i>Outflow</i>)..	49
Tabel 3.8 Struktur Data <i>Outflow</i> dengan Prediktor Variabel <i>Dummy</i>	50
Tabel 4.1 Nilai AIC Residual TSR Skenario 1.	74
Tabel 4.2 Taksiran NIKSP Simulasi Skenario 1.....	76
Tabel 4.3 Nilai AIC Residual TSR Skenario 2	88
Tabel 4.4 Taksiran NIKSP Lag-1 Skenario 2.	89
Tabel 4.5 Taksiran NIKSP Lag-2 Skenario 2.	89
Tabel 4.6 Statistika Deskriptif Data <i>Inflow</i> dan <i>Outflow</i> (dalam milyar).	101
Tabel 4.7 Uji <i>Neglected Nonlinearity</i> pada Data Terhadap Periode Waktu t	102
Tabel 4.8 Nilai AIC Residual TSR Data <i>Outflow</i>	105
Tabel 4.9 Taksiran NIPKS antar Lokasi <i>Outflow</i> untuk Lag 1	114
Tabel 4.10 Nilai AIC Residual <i>Inflow</i>	120
Tabel 4.11 Taksiran NIPKS antar Lokasi <i>Inflow</i> untuk Lag 1.....	129
Tabel 4.12 Nilai AIC Residual Model VAR dan GSTAR	129
Tabel 4.13 Pengujian Residual Distribusi Multivariat Normal Model VAR dan GSTAR	130
Tabel 4.14 Pemilihan Model Terbaik Data Terapan	132

DAFTAR GAMBAR

Gambar 2.1 Contoh Plot MCCF untuk Tiga Variabel <i>Time Series</i>	13
Gambar 2.2 Contoh Plot MPCCF untuk Tiga Variabel <i>Time Series</i>	16
Gambar 2.3 Peta Lokasi Wilayah II KPW BI (Jawa Barat).....	23
Gambar 2.4 Batas Keputusan untuk Set Data	34
Gambar 2.5 <i>Loss Function</i>	35
Gambar 2.6 Batas <i>Error</i> dalam SVR	36
Gambar 2.7 Grafik Fungsi Kernel Linier, Polinomial dan RBF	39
Gambar 3.1 Peta Lokasi Penelitian di Tiga Lokasi di Jawa Barat	45
Gambar 3.2 Ilustrasi Pembentukan Model TSR	68
Gambar 3.3 Ilustrasi Pembentukan Model GSTARX	68
Gambar 3.4 Ilustrasi Pembentukan Model <i>Hybrid</i> GSTARX-SVR	68
Gambar 4.1 Plot <i>Time Series</i> Data Simulasi Residual Linier di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3.....	71
Gambar 4. 2 Boxplot Koefisien Estimasi Parameter dengan Nilai Sebenarnya dengan CI 95% untuk Parameter (a) Tren, (b) Variasi Kalender dan (c) Musiman.	72
Gambar 4. 3 Plot <i>Time Series</i> Residual Data Simulasi Skenario Satu untuk (a) Lokasi 1, (b) Lokasi 2 Dan (c) Lokasi 3.....	73
Gambar 4. 4 Representasi Skematik MCCF Skenario 1 untuk Ketiga Lokasi.	74
Gambar 4. 5 Representasi Skematik MPCCF Simulasi Skenario 1.....	74
Gambar 4. 6 Representasi Skematik MCCF Residual Simulasi Skenario 1.....	75
Gambar 4. 7 Boxplot Koefisien Parameter Level Dua Model GSTAR-GLS Skenario 1.	76
Gambar 4. 8 Koefisien Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Model GSTAR Setiap Replikasi Simulasi Skenario 1 (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3	78

Gambar 4. 9 Standar <i>Error</i> Metode OLS dan GLS Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Setiap Replikasi Simulasi Skenario 1, (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3.	80
Gambar 4. 10 Plot Distribusi Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Metode Estimasi OLS dan GLS Data Simulasi 3 (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3 Skenario 1	81
Gambar 4. 11 Matriks Plot Residual TSR pada Simulasi Residual Linier	81
Gambar 4. 12 <i>Time Series</i> Hasil Peramalan Model VARX-SVR (1) dan GSTARX-SVR (2) di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3 ..	84
Gambar 4. 13 Plot <i>Time Series</i> Data Simulasi Residual Non linier	85
Gambar 4. 14 Plot <i>Time Series</i> Residual Simulasi Skenario 2, (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3.	87
Gambar 4. 15 Representasi Skematik MCCF Skenario 2 di Ketiga Lokasi.	87
Gambar 4. 16 Representasi Skematik MPCCF Skenario 2.	88
Gambar 4. 17 Matriks Plot Residual Simulasi Skenario 2	92
Gambar 4. 18 <i>Time Series</i> Hasil Peramalan Model VARX-SVR (1) dan GSTARX-SVR (2) di (a) Lokasi 1 (b) Lokasi 2 dan (c) Lokasi 3. ..	95
Gambar 4. 19 Nilai RMSE Keempat Model Residual Linier (kiri) dan Residual Non Linier (kanan) di (a) Data <i>Training (in sample)</i> , (b) Data <i>Testing (out sample)</i>	96
Gambar 4. 20 Peningkatan Kebaikan Model Non Linier dari Model Linier untuk Simulasi (a) Residual Linier dan (b) Residual Non Linier.....	96
Gambar 4. 21 Nilai Ramalan Keempat Model Residual Linier (kiri) dan Residual Non Linier (kanan) di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3.....	98
Gambar 4. 22 Plot <i>Time series Inflow</i> dan <i>Outflow</i> di (a) Bandung, (b) Tasikmalaya, (c) Cirebon.	100
Gambar 4. 23 Matriks Plot Residual Data <i>Outflow</i>	103

Gambar 4. 24 Plot <i>Time Series</i> Residual <i>Outflow</i> , (a) Bandung, (b) Tasikmalaya (c) Cirebon	104
Gambar 4. 25 Representasi Skematik MCCF Model $N_t^{(i)}$ Data <i>Outflow</i>	104
Gambar 4. 26 Representasi Skematik MPCCF Residual Data <i>Outflow</i>	104
Gambar 4. 27 <i>Time Series</i> Hasil Peramalan Model VAR-SVR di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon	107
Gambar 4. 28 <i>Time Series</i> Hasil Peramalan Model GSTARX-SVR Bobot Seragam di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon	110
Gambar 4. 29 <i>Time Series</i> Hasil Peramalan Model GSTARX-SVR Bobot Invers Jarak di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon	113
Gambar 4. 30 <i>Time Series</i> Peramalan Model GSTARX-SVR Bobot NIKSP di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon..	116
Gambar 4. 31 Matriks Plot Residual Data <i>Inflow</i>	118
Gambar 4. 32 Plot <i>Time Series</i> Residual <i>Inflow</i> , (a) Bandung, (b) Tasikmalaya dan (c) Cirebon	119
Gambar 4.33 Representasi Skematik MCCF Residual Data <i>Inflow</i>	119
Gambar 4.34 Representasi Skematik MPCCF Residual Data <i>Inflow</i>	119
Gambar 4. 35 <i>Time Series</i> Hasil Peramalan Model VAR-SVR di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon	122
Gambar 4. 36 <i>Time Series</i> Hasil Peramalan Model GSTARX-SVR <i>Inflow</i> Seragam di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon.....	125
Gambar 4. 37 <i>Time Series</i> Hasil Peramalan Model GSTARX-SVR <i>Inflow</i> Invers Jarak di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon	128
Gambar 4. 38 Nilai RMSE Keempat Model Data (a) <i>Outflow</i> dan (b) <i>Inflow</i>	131

Gambar 4. 39 Peningkatan Kebaikan Model <i>Hybrid</i> Dari Model Linier (a)	
<i>Outflow</i> dan (b) <i>Inflow</i>	131
Gambar 4. 40 Peramalan Baik Hingga <i>l</i> -Tahap Kedepan	133
Gambar 4. 41 Nilai Ramalan Keempat Model Data <i>Outflow</i> (kiri) dan <i>Inflow</i>	
(kanan) di (a) Bandung, (b) Tasikmalaya dan (c) Cirebon	135
Gambar 4. 42 Plot Data <i>Training</i> , <i>Testing</i> dan Forecast hingga 2018 untuk	
<i>Outflow</i> dan <i>Inflow</i> di masing-masing Lokasi.....	138

DAFTAR LAMPIRAN

LAMPIRAN 1 Studi Simulasi Residual Linier.....	149
LAMPIRAN 2 Studi Simulasi Residual Nonlinier	165
LAMPIRAN 3 Studi Terapan	183

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Menurut Box, Jenkins, & Reinsel (1994) *time series* merupakan rangkaian pengamatan yang berurutan dalam waktu. Karena kemajuan komputasi dan beberapa masalah dalam peramalan tidak dapat dijawab dengan metode peramalan univariat, peramalan metode multivariat banyak dilakukan dalam beberapa tahun terakhir (De Gooijer dan Hyndman, 2006). Selain itu seiring dengan semakin banyaknya kajian mengenai analisis *time series*, muncul pemikiran adanya dugaan bahwa ada beberapa data yang tidak hanya mengandung keterkaitan dengan kejadian pada waktu-waktu sebelumnya, tetapi juga mempunyai keterkaitan dengan lokasi lain yang berdekatan (*neighbouring*). Kondisi seperti ini disebut dengan data deret *space-time* (waktu dan lokasi). Data *space-time* sering ditemukan di banyak bidang penelitian, misalnya produksi teh bulanan dari beberapa tanaman, harga perumahan tahunan di ibu kota, dan *Gross Domestic Product* (GDP) per kapita tahunan beberapa negara di beberapa wilayah. Terdapat tiga buah pendekatan utama untuk menyelesaikan skenario data *time series* dan lokasi, yaitu model *Vector Autoregressive Integrated Moving Average* (VARIMA), *State Space*, dan *Space-time Autoregressive* (STAR). Ketiga model tersebut menggabungkan unsur dependensi waktu dan lokasi pada data *time series* multivariat.

Model VARIMA menjelaskan keterkaitan antar pengamatan pada variabel tertentu pada suatu waktu dengan pengamatan pada variabel itu sendiri pada waktu-waktu sebelumnya dan juga keterkaitannya dengan pengamatan pada variabel lain pada waktu-waktu sebelumnya. Ramos (2003) telah melakukan peramalan pasar saham dengan menggunakan model VARIMA. *State-space* merupakan salah satu model yang dapat digunakan untuk menggambarkan model VARIMA (Wei, 2006; Box, Jenkins, dan Reinsel, 1994). Untuk model VARIMA dan *state-space* ini dapat juga digunakan untuk menyelesaikan skenario data *time series* dan lokasi.

Model STAR diperkenalkan oleh Pfeifer dan Deutsch (1980a, 1980b) dan telah digunakan dalam sebuah penelitian sosial untuk meramalkan tingkat kejahatan-an pada 14 wilayah di negara bagian Boston Tenggara pada tahun 1980 serta pada berbagai penelitian di tahun berikutnya. Perkembangan penelitian yang mengapli-kasikan model STAR cukup pesat di berbagai bidang. Kyryakidis dan Journal (1999) pada penelitian dengan data geostatistik. Giacomini dan Granger (2004) dalam bidang perekonomian. Selain itu model STAR juga telah diterapkan oleh Kamarianakis dan Prastacos (2005) pada penelitiannya yang mengangkat mengenai transportasi. Model STAR ini pada perkembangannya banyak dikaji oleh beberapa peneliti pemodelan *time series*, antara lain oleh Ruchjana (2001, 2002) dan Suhartono (2003, 2005). Suhartono (2003, 2005) melakukan kajian tentang perbandingan tahapan pembentukan model dan akurasi ramalan antara model STAR dan VARIMA pada suatu data *time series* dan lokasi. Parker dan Swindlehurst (2003) yang menerapkan algoritma STAR sebagai pendekatan untuk mereduksi dimensi dan mempermudah estimasi secara statistik dalam pengapli-kasian penggunaan *Space-Time Adaptive Processing* (STAP). Shoesmith (2013) menggunakan model ini untuk memprediksi tingkat kriminilatas untuk tindak kekerasan dan properti di tingkat regional dan negara bagian di Amerika Serikat khususnya di Florida.

Meskipun telah memperhatikan faktor lokasi, model STAR ini memiliki satu kelemahan, yaitu model ini hanya sesuai untuk diterapkan pada skenario dengan faktor lokasi yang bersifat homogen, sehingga parameter waktu (*autoregresif*) dan lokasi konstan untuk semua lokasi. Sedangkan pada kehidupan nyata lebih banyak dijumpai skenario yang lokasinya cenderung berbeda. Model *Space-Time Auto-regressive* (STAR) yang dikenalkan oleh Pfeifer dan Deutsch mempunyai kele-mahan pada fleksibilitas parameter yang menjelaskan keterkaitan lokasi dan wak-tu yang berbeda pada data *space-time* (Prisandy dan Suhartono, 2008). Kelemahan ini diperbaiki oleh Ruchjana (2002) serta Borovkova, Lopuhaa dan Ruchjana (2002) melalui model yang dikenal dengan model *Generalized Space-Time Auto-regressive* (GSTAR). Istilah generalisasi berkaitan dengan parameter model. Bila parameter matriks diagonal, model GSTAR sama dengan

model STAR yang dibe-rikan oleh Martin dan Oeppen (1975) dan Pfeifer dan Deutsch (1980).

Bila $p=1$ dan $\lambda_1=1$, GSTAR (1;1) disebut orde pertama model GSTAR. Artinya pengamatan saat ini di lokasi tertentu hanya tergantung pada pengamatan satu periode sebelumnya di lokasi yang diminati dan yang terdekat. Orde (1;1) adalah contoh sederhana jika seseorang ingin meramalkan pengamatan di lokasi tertentu. Parameter model GSTAR dapat diestimasi dengan metode *least square*. Dalam makalahnya, Borovkova (2002) menyatakan bahwa masih terdapat peluang untuk melakukan kajian lanjut berkaitan dengan penentuan bobot lokasi yang optimal, sifat-sifat asimtotis dari taksiran model GSTAR, dan perbandingan hasil ketepatan ramalan dibandingkan dengan model-model *time series* multivariat lainnya. Model GSTAR ini pun dapat diterapkan pada data dengan variabel lokasi yang heterogen, dengan pemberian bobot untuk masing-masing lokasi sehingga menghasilkan model *space-time* dengan parameter yang tidak harus sama untuk dependensi waktu maupun lokasi.

Penelitian yang pernah dilakukan mengenai penerapan model GSTAR, antara lain oleh Ippoliti (2001) yang memprediksi *online spatio-temporal* dalam representasi dari model GSTAR dengan memformulasikan *state-space* dari analisis *time series multivariate*. Ruchjana (2002) melakukan pemodelan dengan GSTAR untuk data produksi minyak bumi, model yang didapatkan yaitu GSTAR(1₁) dengan matriks bobot spasial satu dengan estimasi parameter menggunakan metode *least square*. Giacomini dan Granger (2004) yang mengkaji tentang pemodelan GSTAR di bidang perekonomian. Penelitian lainnya adalah Kamarianakis & Prastacos (2005) menerapkan *Space-Time Autoregressive Integrated Moving Average* (STARIMA) untuk memodelkan arus lalu lintas di jalan raya yang ada di pusat kota Athena, Greece. Borovkova dkk. (2008) melakukan penelitian mengenai hasil produksi teh bulanan di Jawa Barat. Pada penelitian tersebut diambil 24 lokasi dengan 94 pengamatan dan estimasinya menggunakan metode *least square*. Gary Deng & George Athanasopoulos (2009) memodelkan data turis domestik di Australia menggunakan model *Space-Time Autoregressive Integrated Moving Average* (STARIMA). Wutsqa (2010) mengaplikasikan metode pembentukan model GSTAR untuk mendapatkan model peramalan data pence-

maran udara di Kota Surabaya. serta Wutsqa dan Suhartono (2010) meramalkan *time series* multivariat musiman pada data pariwisata dengan model VAR-GSTAR. Ningrum (2010) melakukan penerapan model GSTAR pada data curah hujan bulanan di Kabupaten Ngawi. Maghfuro (2012) juga memodelkan data curah hujan di Kabupaten Malang dengan model GSTAR serta membandingkannya dengan ARIMA dan VARIMA. Dalam penelitiannya diketahui bahwa model terbaik untuk pemodelan data curah hujan adalah model GSTAR dengan pembobot normalisasi korelasi silang. Nurhayati, Pasaribu, dan Neswan (2012) juga mengaplikasikan model GSTAR menggunakan data *Gross Domestic Product* (GDP) di 16 negara Eropa barat. Penelitian lainnya yang menerapkan model GSTAR (1,p)-SUR untuk meramalkan curah hujan di kota Batu adalah Iriany, Suhariningsih, Ruchjana, & Setiawan (2013). Anggraeni, Prahutama, dan Andari (2013) melakukan peramalan volume kendaraan masuk tol Semarang. Prastuti (2014) melakukan pemodelan GSTAR-SUR musiman untuk peramalan jumlah wisatawan mancanegara pada empat lokasi wisata di Indonesia. Wahyuningrum (2014) memodelkan inflasi empat kota di Jawa Timur dengan GSTARX-GLS untuk peramalan data *spatio-temporal*. Penerapan metode GSTAR pada Indeks Harga Konsumen (IHK) Jawa tengah di empat kota yaitu Purwokerto, Solo, Semarang dan Tegal menggunakan tiga bobot yakni bobot seragam, bobot invers jarak dan bobot normalisasi korelasi silang (Irawati, 2015).

Prediksi untuk data *time series* dibedakan menjadi dua yaitu dengan pendekatan linier dan non linier. Data *inflow* dan *outflow* di seluruh KPW Bank Indonesia memuat komponen linier dan non linier (Prayoga, 2016). Uji non linieritas dilakukan dengan uji *terasvirta*, dimana uji ini merupakan *neglected non linearity test* dalam *time series* yang digunakan untuk melihat adanya unsur non linieritas pada data. untuk Model *hybrid* bekerja dengan menggabungkan model linier dan nonlinier. Zhang (2003) menunjukkan bahwa model *hybrid* ARIMA-ANN meningkatkan akurasi ramalan dibandingkan dengan model ARIMA dan ANN secara terpisah. Selain menggunakan metode *Neural Network* prediksi data *time series* dengan pendekatan non linier juga bisa dilakukan dengan menggunakan *Support Vector Machine* (SVM). Menurut Vapnik (1998), metode *Support Vector Machine* (SVM) merupakan metode *machine learning* yang baru, sangat berguna

dan berhasil dalam melakukan prediksi baik dalam skenario klasifikasi maupun regresi. Prinsip dasar SVM adalah linier *classifier* yang selanjutnya dikembangkan untuk masalah nonlinier dengan memasukkan konsep *kernel trick* pada ruang ker-ja berdimensi tinggi (Cortez dan Vapnik, 1995). Secara sederhana, konsep SVM adalah usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah class pada *input space* (Rahman dan Purnami, 2012). Metode *Support Vector Machine* (SVM) dikembangkan berdasarkan pada *statistical learning teory* dan *Structural Risk Minimization* (SRM). Jika dibandingkan dengan metode *machine learning* lainnya, SVM mengimplementasikan prinsip *Structural Risk Minimization* (SRM) dari pada *Empirical Risk Minimization* (ERM) (Vapnik, 1995). Menurut teori *Structural Risk Minimization* (SRM), SVM telah memperlihatkan performa sebagai metode yang bisa mengatasi masalah *overfitting* dengan cara meminimalkan batas atas pada *generalization error*, yang menjadi alat yang kuat untuk *supervised learning* (Guo dkk, 2014).

Salah satu modifikasi SVM yang digunakan untuk pedekatan regresi adalah *Support Vector Regression* (SVR). Yasin, Prahutama, dan Utami pada tahun 2014 menerapkan metode SVR untuk memprediksi harga saham dengan menggunakan algoritma *grid search* didapatkan hasil prediksi untuk data *training* mempunyai akurasi yang lebih tinggi dibandingkan dengan prediksi untuk data *testing*. Selain itu ada juga Maharesi pada tahun 2013 yang menggunakan metode SVR pada prediksi *return* saham syariah BEI, yang membuktikan bahwa metode SVR merupakan model yang lebih baik dari pada regresi linier OLS. Konsep dari SVR adalah memaksimalkan *hyperplane* untuk mendapatkan data-data yang menjadi *support vector*. Keunggulan SVR salah satunya adalah mampu mengatasi *overfitting* (Yasin, Prahutama, Utami 2014).

Walaupun dewasa ini sistem pembayaran non-tunai berkembang dengan cepat seiring dengan perkembangan teknologi dan inovasi di pasar uang, keberadaan uang kertas dan uang logam yang disebut dengan uang kartal masih memegang peranan penting dalam perekonomian. Rasio jumlah uang tunai terhadap nilai total transaksi pembayaran yang terjadi di Kanada mencapai 35%-80%, di Thailand mencapai lebih dari 70%, dan di Inggris mencapai hampir 75% (Sigalingging, Setiawan, & Sihalo, 2004).

Selama kurun waktu 2000-2005, laju pertumbuhan UYD, *inflow*, dan *outflow* rata-rata per tahun meningkat masing-masing sebesar 10,25%, 16,33%, dan 14,95% (Pramono, Yanuarti, Purusitawati, & Emmy, 2006). Begitu pula pada tahun 2012 jumlah UYD mengalami peningkatan dari tahun 2011. Rata-rata harian UYD naik dari Rp 320,37 triliun pada tahun 2011 menjadi Rp 370,61 triliun pada tahun 2012 atau meningkat 15,68%. Hal ini mengindikasikan adanya peningkatan kebutuhan uang kartal sebagai alat pembayaran tunai di masyarakat. Peningkatan ini dikonfirmasi pula dengan tambahan kebutuhan uang kartal (*net outflow*) sepanjang tahun 2012 sebesar Rp 63,29 triliun atau meningkat 16,80% dibandingkan tahun 2011 sebesar Rp 54,19 triliun. Sementara itu, pasca penerapan penyempurnaan ketentuan penyetoran dan penarikan uang rupiah oleh bank umum di Bank Indonesia, laju pertumbuhan jumlah aliran uang kartal yang keluar (*outflow*) dan masuk (*inflow*) melalui Bank Indonesia pada tahun 2012 turun dibandingkan tahun 2011. Jumlah *outflow* dan *inflow* masing-masing tumbuh sebesar 23,57% dan 24,82%, menurun dibandingkan pertumbuhan tahun 2011 sebesar 40,55% dan 39,06%. Penurunan tersebut merupakan dampak penyempurnaan ketentuan sehingga penggunaan uang kartal lebih optimal yang pada gilirannya dapat meningkatkan efisiensi baik bagi perbankan maupun Bank Indonesia.

Banyaknya *inflow* dan *outflow* yang akan dikeluarkan tergantung kebijakan yang telah diambil di masing-masing Kantor Bank Indonesia yang ada di setiap wilayah. Provinsi Jawa Barat memiliki *inflow* terbesar ke 3 di tingkat nasional setelah DKI Jakarta dan Jawa Timur pada triwulan II 2017. Wilayah II KPW BI (Jawa Barat) memiliki tiga KBI (Bandung, Cirebon dan Tasikmalaya). Studi pertumbuhan ekonomi Jawa Barat menunjukkan hubungan masing-masing kota dengan menggunakan metode spasial. *Inflow* dan *Outflow* wilayah Jawa Barat di tiga KBI selain dipengaruhi oleh waktu sebelumnya juga mempunyai keterkaitan dengan lokasi lain yang disebut hubungan spasial. Jawa Barat dipilih karena dalam lima tahun terakhir provinsi ini mengalami pertumbuhan ekonomi di atas rata-rata nasional. Pada triwulan II 2017, Wilayah II KPW BI (Jawa Barat) mengalami *net outflow* sebesar Rp 8,76 triliun. Pada Juli 2017 Wilayah II KPW BI (Jawa Barat) menempati peringkat ketiga setelah Wilayah I KPW BI (DKI Jakarta) dan Wilayah IV KPW BI (Jawa Timur) dengan total *outflow* sebesar Rp 1,32 Triliun. Sela-

in itu dalam delapan tahun terakhir (2010-2017) Wilayah II KPW BI (Jawa Barat) termasuk dalam empat wilayah dengan rata-rata *outflow* terbesar yaitu sebesar Rp 9,57 triliun (Bank Indonesia, 2017).

Ahmad, Setiawan, Suhartono dan Masun (2015) melakukan peramalan *inflow* dan *outflow* di Wilayah IV KPW BI (Jawa Timur) disimpulkan bahwa model peramalan terbaik untuk *inflow* mata uang di Indonesia KBI Surabaya, Malang, Kediri dan Jember secara berurutan adalah sebagai berikut: model variasi kalender, fungsi transfer, ARIMA, dan *time series regression*. Hasil ini menunjukkan bahwa model yang lebih kompleks mungkin belum menghasilkan prediksi yang lebih akurat sebagaimana hasil Kompetisi M3. Pada tahun yang sama dilakukan peramalan *inflow* dan *outflow* di Wilayah III KPW BI (Jawa Tengah) oleh Setiawan, Suhartono, Ahmad dan Rahmawati (2015). Hasil analisis menunjukkan bahwa model terbaik untuk meramalkan *inflow* adalah model ARIMA. Sedangkan untuk meramalkan *outflow* adalah model ARIMAX atau *Time Series Regression*, karena keduanya memiliki persamaan model. Hasil penelitian Apriliadara, Suhartono dan Prastyo (2016) menunjukkan bahwa dinamika *inflow* mata uang dipengaruhi oleh jumlah *outflow* begitu pula sebaliknya. Selain itu, bukti empiris juga membuktikan bahwa Idul Fitri berpengaruh signifikan baik pada *inflow* maupun *outflow*.

Husna (2013) melakukan pemodelan pada data inflasi di Jabodetabek menggunakan GSTAR dengan memberikan 4 jenis bobot lokasi yaitu bobot seragam, bobot invers jarak, bobot normalisasi silang, dan biner. Pada penelitian tersebut dihasilkan bahwa bobot terbaik yang sesuai untuk memodelkan inflasi adalah bobot invers jarak. Rahman (2013) menyimpulkan *lagrange multiplier test* merupakan prosedur yang efektif untuk pemilihan input optimum model SVR. Model SVR lebih baik dibandingkan model ARIMAX. Mubarak (2015) melakukan pemodelan GSTAR dengan variabel eksogen untuk peramalan arus uang di Wilayah IV KPW BI (Jawa Timur) menunjukkan model GSTAR pada level dua yang terbentuk adalah GSTAR (3₁) untuk data *inflow* dan GSTAR([1,3]₁) untuk data *outflow* di empat kota/kabupaten di Jawa Timur. Safitri (2016) melakukan peramalan *outflow* di Wilayah IV KPW BI (Jawa Timur) dengan metode GSTAR, TSR dan GSTAR-SUR diperoleh kesimpulan model *Time*

Series Regression tanpa efek variasi kalender lebih baik memodelkan *outflow* uang pecahan 100 ribu di empat KBI di Jawa Timur, sedangkan model GSTAR lebih baik memodelkan *outflow* uang pecahan 2 ribu. Fina (2016) melakukan peramalan *outflow* di Wilayah III KPW BI (Jawa Tengah) dengan metode GSTAR diperoleh kesimpulan data *outflow* di KBI Semarang, Solo dan Purwokerto dipengaruhi oleh dua periode waktu sebelumnya, sedangkan untuk data *outflow* di KBI Tegal dipengaruhi oleh waktu sebelumnya dan tiga *outflow* di tiga KBI lainnya. Nabila (2016) melakukan pemodelan GSTAR dengan bobot normalisasi korelasi silang dengan melibatkan variabel signifikan. Berdasarkan pemaparan diatas dalam penelitian ini diterapkan metode VARX, GSTARX, *Hybrid* VARX-SVR dan *Hybrid* GSTARX-SVR untuk pemodelan *inflow* dan *outflow* uang kartal di tiga Kantor Bank Indonesia (KBI) di Jawa Barat yaitu Bandung, Cirebon dan Tasikmalaya menggunakan 3 bobot yakni bobot seragam, bobot invers jarak, dan bobot normalisasi inferensi korelasi silang parsial.

1.2 Rumusan Masalah

Data *inflow* dan *outflow* memiliki keragaman yang besar pada skala ruang dan waktu, sehingga sehingga pada penelitian ini digunakan metode pemodelan *Vector Autoregressive* dan *Generalized Space-Time Autoregressive*. Berdasarkan penelitian sebelumnya, data *inflow* dan *outflow* di seluruh KPW Bank Indonesia memuat komponen linier dan non linier (Prayoga, 2016). Hal ini dapat dikarenakan adanya kebijakan Bank Indonesia serta adanya data *outlier*. Penelitian ini menggunakan metode pemodelan *Hybrid* VARX-SVR dan *Hybrid* GSTARX-SVR yang merupakan kombinasi metode linier dan non linier. Berdasarkan hasil yang nantinya diperoleh dapat diketahui hasil peramalan dari metode yang terbaik. Metode pemodelan yang terbaik dipilih berdasarkan kriteria *root mean square of error (RMSE) out sample*.

1.3 Tujuan Penelitian

Berdasarkan rumusan masalah di atas, maka tujuan yang ingin diperoleh dari penelitian adalah sebagai berikut:

1. Mendapatkan model VARX, *Hybrid* VARX-SVR, GSTARX dan *Hybrid* GSTARX-SVR pada studi simulasi dengan skenario residual linier dan non linier.
2. Mendapatkan model VARX, *Hybrid* VARX-SVR, GSTARX dan *Hybrid* GSTARX-SVR pada studi terapan untuk meramalkan *inflow* dan *outflow* di KBI Bandung, KBI Cirebon dan KBI Tasikmalaya.
3. Memperoleh hasil ramalan dari model terbaik pada data *inflow* dan *outflow* di KBI Bandung, KBI Cirebon dan KBI Tasikmalaya.

1.4 Manfaat Penelitian

Manfaat yang akan diperoleh dari penelitian ini adalah sebagai berikut:

1. Memberikan tambahan informasi mengenai pertimbangan dalam mengeluarkan kebijakan moneter khususnya mengenai peredaran uang terutama untuk wilayah Jawa Barat.
2. Menambah kontribusi keilmuan khususnya dalam bidang statistika sebagai pengembangan dari penerapan metode *Hybrid* VARX-SVR dan *Hybrid* GSTARX-SVR.
3. Hasil penelitian dapat digunakan sebagai bahan referensi bagi penelitian-penelitian selanjutnya.

1.5 Batasan Masalah

Batasan masalah dalam penelitian ini adalah sebagai berikut:

1. Penelitian tugas akhir ini dilakukan hanya pada KBI Bandung, KBI Cirebon dan KBI Tasikmalaya di Provinsi Jawa Barat karena berbagai pertimbangan.
2. Orde spasial yang digunakan adalah orde satu karena wilayah kerja masing-masing KBI berdekatan secara langsung.
3. *Series* waktu untuk setiap kota adalah selama 11 tahun.

Halaman ini sengaja dikosongkan

BAB 2

TINJAUAN PUSTAKA

Pada bab ini diuraikan tinjauan pustaka yang mendukung penyelesaian permasalahan dalam penelitian. Terdapat beberapa hal yang akan dibahas, yaitu *multivariate time series*, model VARIMA, STAR, GSTAR, SVR serta kajian non statistika mengenai pengedaran uang di Indonesia.

2.1 Analisis *Multivariate Time Series*

Analisis *time series* adalah salah satu metode peramalan secara matematis dengan menggunakan waktu sebagai acuan, kemudian membuat prediksi dengan menggunakan ekstrapolasi berdasarkan waktu untuk pola-pola tersebut (Muhtaram, 2011). Analisis *time series* yang hanya menggunakan satu data saja disebut sebagai *time series* univariat. Beberapa skenario penelitian yang telah berkembang memerlukan suatu analisis *time series* yang mempertimbangkan berbagai variabel *time series* secara simultan, analisis ini disebut dengan analisis *multivariate time series* (Tsay, 2014).

Sama halnya dengan *time series* univariat, stasioneritas pada data *time series* multivariat juga dapat dilihat dari plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF) yang terbentuk. Plot MCCF yang turun secara perlahan mengindikasikan bahwa data belum stasioner dalam rata-rata sehingga perlu dilakukan diferensi untuk menstasionerkan data. Demikian juga saat data tidak stasioner dalam varians maka perlu dilakukan transformasi agar memperoleh data yang stasioner (Wei, 2006)

2.1.1 *Matrix Cross Correlation Function* (MCCF)

Jika terdapat sebuah vektor *time series* dengan observasi sebanyak n , yaitu $\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_n$, maka persamaan matriks korelasi sampelnya adalah sebagai berikut, (Wei, 2006)

$$\hat{\rho}(k) = [\hat{\rho}_{ij}(k)] \quad (2.1)$$

dengan $\hat{\rho}_{ij}(k)$ adalah korelasi silang sampel untuk komponen *series* ke- i dan ke- j

yang dinyatakan dalam persamaan berikut,

$$\hat{\rho}_{ij}(k) = \frac{\sum_{t=1}^{n-k} (Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)}{\sqrt{\left(\sum_{t=1}^n (Y_{i,t} - \bar{Y}_i)^2 \sum_{t=1}^n (Y_{j,t} - \bar{Y}_j)^2 \right)}} \quad (2.2)$$

dengan \bar{Y}_i dan \bar{Y}_j merupakan rata-rata sampel dari komponen *series* yang berse-suaian. Sebagai catatan, $\gamma_{ij}(k) \neq \gamma_{ij}(-k)$ untuk $i \neq j$ sehingga $\Gamma(k) \neq \Gamma(-k)$. Karena $\gamma_{ij}(k) = E[(Y_{i,t} - \bar{Y}_i)(Y_{j,t+k} - \bar{Y}_j)] = E[(Y_{j,t+k} - \bar{Y}_j)(Y_{i,t} - \bar{Y}_i)] = \gamma_{ji}(-k)$, didapatkan $\Gamma(k) = \Gamma'(-k)$ dan $\mathbf{\rho}(k) = \mathbf{\rho}'(-k)$. Bartlett dalam Wei (2006) telah menurunkan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Berdasarkan hipotesis bahwa dua data *time series* Y_i dan Y_j tidak berkorelasi, sehingga Bartlett menunjukkan persamaan sebagai berikut,

$$\text{Varians}[\hat{\rho}_{ij}(k)] \cong \frac{1}{n-k} \left[1 + 2 \sum_{s=1}^{\infty} \rho_{ii}(s) \rho_{jj}(s) \right], |k| > q \quad (2.3)$$

ketika Y_i dan Y_j merupakan deret yang *white noise* selanjutnya akan diperoleh persamaan sebagai berikut,

$$\text{Cov}[\hat{\rho}_{ij}(k), \hat{\rho}_{ij}(k+s)] \cong \frac{1}{n-k} \quad (2.4)$$

$$\text{Var}[\hat{\rho}_{ij}(k)] \cong \frac{1}{n-k} \quad (2.5)$$

untuk ukuran sampel yang besar, $(n-k)$ dalam persamaan diatas (2.5) seringkali digantikan dengan n .

Matrik korelasi sampel sangat berguna dalam mengidentifikasi orde model *moving average* (MA). Box dan Tiao (1981) dalam Wei (2006) memperkenalkan metode meringkas hasil korelasi sampel. Dengan metode ini menggunakan simbol (+), (-), dan (.) pada baris ke- i dan kolom ke- j matrik korelasi sampel, yaitu:

1. simbol (+) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih besar dari 2 kali nilai estimasi *standard error* (SE) artinya bahwa komponen (i,j) memiliki korelasi positif,

2. simbol (-) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ lebih kecil dari -2 kali nilai estimasi *standard error* (SE) memiliki arti bahwa komponen (i,j) memiliki korelasi negatif, dan
3. simbol (.) menunjukkan bahwa nilai $\hat{\rho}_{ij}(k)$ terletak diantara ± 2 kali nilai estimasi *standard error* memiliki arti bahwa komponen (i,j) tidak memiliki korelasi.

Data telah dikatakan stasioner jika plot MCCF sedikit atau jarang menampilkan tanda (+) dan (-) dan hampir semua tanda bersimbol (.).

Tabel 2.1 Contoh Nilai MCCF untuk Tiga Variabel *Time Series*

Lag	0			1			2		
Variabel	y_1	y_2	y_3	y_1	y_2	y_3	y_1	y_2	y_3
y_1	1,00	0,31	0,18	0,35	0,12	0,15	0,06	0,06	-0,02
y_2	0,31	1,00	0,22	0,20	0,23	0,35	0,20	-0,06	0,09
y_3	0,18	0,22	1,00	0,42	0,18	0,26	0,31	0,11	0,16

Sebagai contoh, hasil perhitungan nilai-nilai MCCF dari tiga data *time series* dengan masing-masing *series* terdiri dari 100 observasi ditunjukkan pada Tabel 2.1. Nilai batas ± 2 kali estimasi standar *error* didapat dari perhitungan seperti pada persamaan (2.6)

$$\begin{aligned}\pm 2 \times \text{SE}(\rho_{ij}(1)) &= \pm 2 \times \sqrt{\frac{1}{100-1}} \\ &= \pm 0,2.\end{aligned}\tag{2.6}$$

Nilai-nilai MCCF pada Tabel 2.1 selanjutnya dinotasikan ke dalam bentuk simbol dengan batas $\pm 0,2$ yang ditampilkan dalam Gambar 2.1 sebagai berikut,

<i>Lag k</i>	0	1	2
y_1	++.	+++	.++
y_2	+++	.+.	...
y_3	.++	.++	...

Gambar 2.1 Contoh Plot MCCF untuk Tiga Variabel *Time Series*

2.1.2 *Matrix Partial Cross Correlation Function* (MPCCF)

Fungsi autokorelasi parsial (PACF) diperlukan dalam *time series* univariat untuk menentukan orde dalam model AR. Generalisasi dari konsep

PACF ke dalam bentuk vektor *time series* dilakukan oleh Tiao dan Box (1981) dalam Wei (2006), yang mendefinisikan matriks autoregresi parsial pada lag s dengan notasi $P(s)$, sebagai koefisien matriks terakhir ketika data diterapkan ke dalam suatu proses *Vector Autoregressive* (VAR) dari orde s . $P(s)$ sama dengan $\Phi_{s,s}$ dalam regresi linier multivariat. Persamaan matriks autoregresi parsial diperoleh (Wei, 2006)

$$P(s) = \begin{cases} \Gamma'(1)[\Gamma(0)]^{-1}, & s = 1 \\ \{\Gamma'(s) - \mathbf{c}'(s)[\mathbf{A}(s)]^{-1}\mathbf{b}(s)\} \{\Gamma(0) - \mathbf{b}'(s)[\mathbf{A}(s)]^{-1}\mathbf{b}(s)\}^{-1}, & s > 1 \end{cases} \quad (2.7)$$

Jika model dari data merupakan vektor AR(p), maka

$$P(s) = \begin{cases} \Phi_p, & s = p \\ 0, & s > p \end{cases} \quad (2.8)$$

sama halnya dengan persamaan autokorelasi parsial pada skenario data univariat, persamaan matriks parsial autoregresi, $P(s)$, juga memiliki sifat *cut-off* untuk vektor proses AR.

Notasi $\Phi_{s,s}$ dalam regresi linier multivariat

$$\mathbf{Y}_{t+s} = \Phi_{s,1} \mathbf{Y}_{t+s+1} + \Phi_{s,2} \mathbf{Y}_{t+s+2} + \dots + \Phi_{s,s} \mathbf{Y}_t + \mathbf{e}_{s,t+s} \quad (2.9)$$

Heyse dan Wei (1985a,b) memperluas definisi parsial autokorelasi univariat menjadi vektor *time series* dan memperoleh matrik korelasi antara \mathbf{Y}_t dan \mathbf{Y}_{t+s} . Matrik korelasi yang ditegaskan sebagai korelasi antar vektor *residual* memiliki persamaan sebagai berikut,

$$\begin{aligned} \mathbf{u}_{s-1,t+s} &= \mathbf{Y}_{t+s} - \alpha_{s-1,1} \mathbf{Y}_{t+s-1} - \dots - \alpha_{s-1,s-1} \mathbf{Y}_{t+1} \\ &= \begin{cases} \mathbf{Y}_{t+s} - \sum_{k=1}^{s-1} \alpha_{s-1,k} \mathbf{Y}_{t+s-k}, & s \geq 2, \\ \mathbf{Y}_{t+1}, & s = 1. \end{cases} \end{aligned} \quad (2.10)$$

dan

$$\begin{aligned} \mathbf{v}_{s-1,t} &= \mathbf{Y}_t - \beta_{s-1,1} \mathbf{Y}_{t+1} - \dots - \beta_{s-1,s-1} \mathbf{Y}_{t+s-1} \\ &= \begin{cases} \mathbf{Y}_t - \sum_{k=1}^{s-1} \beta_{s-1,k} \mathbf{Y}_{t+k}, & s \geq 2, \\ \mathbf{Y}_t, & s = 1. \end{cases} \end{aligned} \quad (2.11)$$

Matrik koefisien regresi linier multivariat $\mathbf{a}_{s-1,k}$ dan $\mathbf{\beta}_{s-1,k}$ diminimalisasi menjadi $E[\|\mathbf{u}_{s-1,t+s}\|^2]$ dan $E[\|\mathbf{v}_{s-1,t}\|^2]$. Minimum dari persamaan diatas untuk generalisasi multivariat didapat persamaan

$$\begin{aligned}\mathbf{A}(s)\mathbf{a}'(s) &= \mathbf{c}(s) \\ \mathbf{A}(s)\mathbf{\beta}'(s) &= \mathbf{b}(s)\end{aligned}\tag{2.12}$$

$$\begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \cdots & \Gamma(0) \end{bmatrix} \begin{bmatrix} \mathbf{a}'_{s-1,1} \\ \mathbf{a}'_{s-1,2} \\ \vdots \\ \mathbf{a}'_{s-1,s-1} \end{bmatrix} = \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}\tag{2.13}$$

untuk $s \geq 2$, didapatkan nilai $\mathbf{A}(s)$, $\mathbf{b}(s)$, dan $\mathbf{c}(s)$ adalah sebagai berikut,

$$\begin{aligned}\mathbf{A}(s) &= \begin{bmatrix} \Gamma(0) & \Gamma'(1) & \cdots & \Gamma'(s-2) \\ \Gamma(1) & \Gamma(0) & \cdots & \Gamma'(s-3) \\ \vdots & \vdots & \ddots & \vdots \\ \Gamma(s-2) & \Gamma(s-3) & \cdots & \Gamma(0) \end{bmatrix}, & \mathbf{b}(s) &= \begin{bmatrix} \Gamma'(s-1) \\ \Gamma'(s-2) \\ \vdots \\ \Gamma'(1) \end{bmatrix}, \\ \mathbf{c}(s) &= \begin{bmatrix} \Gamma(1) \\ \Gamma(2) \\ \vdots \\ \Gamma(s-1) \end{bmatrix}, & \mathbf{a}(s) &= \begin{bmatrix} \mathbf{a}'_{s-1,1} \\ \mathbf{a}'_{s-1,2} \\ \vdots \\ \mathbf{a}'_{s-1,s-1} \end{bmatrix}, & \mathbf{\beta}'(s) &= \begin{bmatrix} \mathbf{\beta}'_{s-1,s-1} \\ \mathbf{\beta}'_{s-1,s-2} \\ \vdots \\ \mathbf{\beta}'_{s-1,1} \end{bmatrix}\end{aligned}$$

sehingga $\text{var}(\mathbf{u}_{s-1,t+s})$ dapat ditulis sebagai $\mathbf{V}_u(s)$, $\text{var}(\mathbf{v}_{s-1,t})$ adalah $\mathbf{V}_v(s)$ dan $\text{cov}(\mathbf{v}_{s-1,t}, \mathbf{u}_{s-1,t+s})$ sebagai $\mathbf{V}_{vu}(s)$. Kemudian Heyse dan Wei (1985a, 1985b) mendapatkan persamaan untuk matriks autokorelasi lag parsial pada lag s sebagai berikut, (Wei, 2006)

$$\mathbf{P}(s) = [\mathbf{D}_v(s)]^{-1} \mathbf{V}_{vu}(s) [\mathbf{D}_u(s)]^{-1}\tag{2.14}$$

dengan $\mathbf{D}_v(s)$ adalah matrik diagonal dimana elemen ke- i merupakan akar dari elemen diagonal ke- i dari $\mathbf{V}_v(s)$, dan $\mathbf{D}_u(s)$ didefinisikan sama untuk $\mathbf{V}_u(s)$.

Tabel 2.2 Contoh Nilai MPCCF untuk Tiga Variabel *Time Series*

<i>Lag</i>	1			2			3		
Variabel	y_1	y_2	y_3	y_1	y_2	y_3	y_1	y_2	y_3
y_1	0,31	0,02	0,06	-0,12	0,05	-0,11	-0,01	0,09	0,01
y_2	0,07	0,17	0,29	0,05	-0,18	-0,02	-0,14	0,03	0,23
y_3	0,36	0,06	0,19	0,12	0,02	0,06	0,19	0,02	-0,13

Identifikasi data dipermudah berdasarkan nilai MPCCF, maka nilai-nilai MPCCF juga dinotasikan dalam bentuk simbol (+), (-), dan (.) seperti pada MCCF. Contoh nilai-nilai hasil perhitungan MPCCF ditampilkan dalam Tabel 2.2. Sama halnya dengan MCCF, nilai batas ± 2 kali estimasi standar *error* didapat dari perhitungan seperti pada persamaan (2.6), yaitu $\pm 0,2$. Berikut bentuk simbol dari nilai-nilai MPCCF pada Tabel 2.2 ditampilkan dalam Gambar 2.2.

k	0	1	2
y_1	+.+
y_2
y_3	.+.+.

Gambar 2.2 Contoh Plot MPCCF untuk Tiga Variabel *Time Series*

2.2 Model Vector Autoregressive Integrated Moving Average

Model *Vector Autoregressive Integrated Moving Average* (VARIMA) merupakan generalisasi dari model univariat ARIMA. Seperti pada ARMA, analisis ini juga memperhatikan stasioneritas data dan hal ini dapat dilihat dari plot *Matrix Cross Correlation Function* (MCCF) dan *Matrix Partial Cross Correlation Function* (MPCCF) serta plot *Box-Cox*. Perlakuan terhadap data multivariat yang tidak stasioner sama dengan data univariat yang tidak stasioner. Data multivariat yang tidak stasioner dalam varians di transformasi agar data dapat stasioner, dan jika tidak stasioner dalam rata-rata dilakukan *differencing* untuk menstasionerkannya. Secara umum model VARIMA (p,d,q) dapat dituliskan dalam bentuk (Wei, 2006)

$$\Phi_p(B)D(B)\dot{Y}_t = \Theta_q(B)e_t, \quad (2.15)$$

dengan $\dot{Y}_t = (Y_{1,t}, Y_{2,t}, \dots, Y_{m,t})'$ merupakan vektor respon yang terkoreksi nilai rata-rata, $\Phi_p(B)$ dan $\Theta_q(B)$ merupakan suatu matriks koefisien AR(p) dan MA(q), $D(B)$ merupakan operator proses diferensi yang dinyatakan dengan $diag((1-B)^{d_1}, (1-B)^{d_2}, \dots, (1-B)^{d_m})$, dan $e(t) \sim IIDN(0, \Omega)$. Model VARIMA juga dapat dituliskan

$$\dot{Y}_t = \Phi_1 \dot{Y}_{t-1} + \dots + \Phi_p \dot{Y}_{t-p} + e_t - \Theta_1 e_{t-1} - \dots - \Theta_q e_{t-q}. \quad (2.16)$$

Misalkan untuk lokasi sebanyak tiga dengan orde p dan $q = 1$, maka persamaan (2.16) dalam bentuk matriks juga dapat dituliskan

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} = \begin{bmatrix} \varphi_{11} & \varphi_{12} & \varphi_{13} \\ \varphi_{21} & \varphi_{22} & \varphi_{23} \\ \varphi_{31} & \varphi_{32} & \varphi_{33} \end{bmatrix} \begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} + \begin{bmatrix} e_t^{(1)} \\ e_t^{(2)} \\ e_t^{(3)} \end{bmatrix} - \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} \\ \theta_{21} & \theta_{22} & \theta_{23} \\ \theta_{31} & \theta_{32} & \theta_{33} \end{bmatrix} \begin{bmatrix} e_t^{(1)} \\ e_t^{(2)} \\ e_t^{(3)} \end{bmatrix}. \quad (2.17)$$

2.2.1 Estimasi Parameter Model VARIMA

Estimasi parameter untuk skenario univariat dapat digeneralisasikan menjadi bentuk matriks $\Phi = (\Phi_1, \dots, \Phi_p)$, $\Theta = (\Theta_1, \dots, \Theta_q)$ dan Σ . Salah satu metode estimasi yang dapat digunakan adalah *Maximum Likelihood Estimation* (MLE). Misalkan $\mathbf{Y} = (\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_n)$ menyatakan suatu proses VARMA(p, q), maka fungsi *log likelihood*-nya (Wei, 2006)

$$\begin{aligned} \ln L(\Phi, \Theta, \Sigma | \mathbf{Y}) &= -\frac{nm}{2} \ln(2\pi) - \frac{n}{2} \ln |\Sigma| - \frac{1}{2} \sum_{t=1}^n \mathbf{e}_t' \Sigma^{-1} \mathbf{e}_t \\ &= -\frac{nm}{2} \ln(2\pi) - \frac{n}{2} \ln |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1} S(\Phi, \Theta), \end{aligned} \quad (2.18)$$

dengan

$$\mathbf{e}_t = \mathbf{Y}_t - \Phi_1 \mathbf{Y}_{t-1} - \dots - \Phi_p \mathbf{Y}_{t-p} + \Theta_1 \mathbf{e}_{t-1} + \dots + \Theta_q \mathbf{e}_{t-q} \quad (2.19)$$

dan

$$S(\Phi, \Theta) = \sum_{t=1}^n \mathbf{e}_t \mathbf{e}_t'. \quad (2.20)$$

Misalkan β merupakan suatu parameter pada model VARMA (mencakup Φ dan Θ) dan $\hat{\beta}$ merupakan taksiran dari β , maka pengujian signifikansi parameter dapat dinyatakan

$$H_0 : \beta_{ij} = 0,$$

$$H_1 : \beta_{ij} \neq 0$$

statistik uji:

$$t = \frac{\hat{\beta}_{ij}}{SE(\hat{\beta}_{ij})} \quad (2.21)$$

dengan $i = 1, 2, \dots, m$ dan $j = 1, 2, \dots, m$. Statistik uji (2.21) kemudian dibandingkan dengan $t_{\alpha/2}$ yang diperoleh dari tabel distribusi t . Hipotesis nol akan ditolak, jika

nilai $|t| > t_{\alpha/2; n-p-1}$, dengan $SE(\hat{\beta}_{ij})$ merupakan standar *error* dari nilai taksiran β dan p menunjukkan banyaknya parameter yang ditaksir serta α adalah tingkat signifikansi.

Selanjutnya dengan metode *least square* yang meminimumkan jumlah kuadrat *error* diperoleh hasil persamaan untuk nilai estimasi parameter $\hat{\Phi}$, misal dalam hal ini menggunakan model VAR(p), (Wutsqa dan Suhartono, 2010). Misalkan \mathbf{Y}_t menyatakan suatu proses m -variat VAR(p),

$$\mathbf{Y}_t = \Phi_1 \mathbf{Y}_{t-1} + \dots + \Phi_p \mathbf{Y}_{t-p} + \mathbf{e}_t \quad (2.22)$$

dengan $\mathbf{e}_t \sim IIDN(0, \Sigma)$, maka nilai estimasi parameter $\hat{\Phi}$ seperti pada persamaan (2.23) berikut,

$$\hat{\Phi}' = \left[\sum_{t=1}^n \mathbf{Y}_t \mathbf{Y}_t' \right] \left[\sum_{t=1}^n \mathbf{Y}_t \mathbf{Y}_{t-1}' \right]^{-1} \quad (2.23)$$

dimana \mathbf{Y}_t merupakan vektor berukuran $mp \times 1$ sebagai berikut,

$$\mathbf{Y}_t = \begin{bmatrix} \mathbf{Y}_{t-1} \\ \mathbf{Y}_{t-2} \\ \vdots \\ \mathbf{Y}_{t-p} \end{bmatrix} \quad (2.24)$$

2.2.2 Pemeriksaan Diagnostik Model VARIMA

Setelah estimasi parameter diperoleh, maka selanjutnya kecukupan dari kesesuaian model harus diperiksa dengan analisis diagnosa dari residual (Wei, 2006)

$$\hat{\mathbf{e}}_t = \dot{\mathbf{Y}}_t - \hat{\Phi}_1 \dot{\mathbf{Y}}_{t-1} - \dots - \hat{\Phi}_p \dot{\mathbf{Y}}_{t-p} + \hat{\Theta}_1 \hat{\mathbf{e}}_{t-1} + \dots + \hat{\Theta}_q \hat{\mathbf{e}}_{t-q}, \quad (2.25)$$

dengan $\dot{\mathbf{Y}}_t$ digunakan untuk menotasikan \mathbf{Y}_t jika $\mu = 0$ dan menotasikan $(\mathbf{Y}_t - \hat{\mu})$, dimana $\hat{\mu}$ merupakan vektor rata-rata, serta $\hat{\Phi}_i$ dan $\hat{\Theta}_j$ adalah nilai taksiran dari parameter Φ_i dan Θ_j . Model *time series* dikatakan cukup jika residual bersifat *white noise*. Maka dari itu, matriks korelasi dari $\hat{\mathbf{e}}_t$ nilainya harus sama dengan nol.

Uji *Portmanteau* diperkenalkan pertama kali oleh Box-Pierce (1970) dan digunakan untuk mengetahui signifikansi keseluruhan dari autokorelasi residual sampai lag- k . Hal ini dirancang untuk hipotesis sebagai berikut,

$$H_0: \rho_1^{(ij)} = \dots = \rho_k^{(ij)} = 0$$

$$H_1: \text{minimal ada satu } \rho_k^{(ij)} \neq 0; \quad \text{dengan } k = 1, 2, \dots, K$$

statistik uji:

$$Q = N \sum_{k=1}^K \left(\rho_k^{(ij)} \right)^2 \quad (2.26)$$

statistik uji Q akan menyebar mengikuti distribusi *chi-square*, $\chi_{\alpha; (K-p-q)}^2$. Uji *Portmanteau* dalam perkembangannya menunjukkan bahwa pada sampel terbatas akan menghasilkan distribusi yang tidak mendekati distribusi *chi-square*. Fakta ini yang menjadi titik awal dari beberapa modifikasi, salah satunya usulan perbaikan dari Ljung-Box (1987). Sehingga uji *Portmanteau* ini diperbaiki menjadi uji *Portmanteau Ljung-Box* dengan menggantikan koefisien autokorelasi *residual* ($\rho_k^{(ij)}$) dengan nilai standarnya ($\hat{\rho}_k^{(ij)}$), Peña dan Rodríguez (2002). Dengan demikian, statistik ujinya menjadi seperti persamaan berikut,

$$Q_{LB} = N(N+2) \sum_{k=1}^K \frac{1}{N-k} \text{tr} \left[\hat{C}_{0j} \hat{C}_{00}^{-1} \hat{C}_{0j}' \hat{C}_{00}^{-1} \right]; \quad \hat{C}_{0j} = N^{-1} \sum_{n=k+1}^N \hat{\rho}_n \hat{\rho}_{n-k}' \quad (2.27)$$

Statistik uji *Portmanteau Ljung-Box* juga menyebar mengikuti distribusi *chi-square*, $\chi_{\alpha; (K-p-q)}^2$.

2.2.3 Peramalan Model VARIMA

Model VARIMA(p, q) pada lokasi ke- i dan dengan peramalan l tahap kedepan pada waktu awal yang sama, yaitu T diberikan dengan (Tsay, 2002)

$$\hat{\mathbf{Y}}_{i,T}(l) = \sum_{p=1}^P \mathbf{\Phi}_p \mathbf{Y}_{n+l-p} - \sum_{q=1}^Q \mathbf{\Theta}_q \mathbf{e}_{n+l-q}, \quad (2.28)$$

dan *error* dari peramalan pada persamaan (2.28) dinyatakan dalam bentuk

$$\mathbf{e}_{i,T}(l) = \mathbf{Y}_{n+l} - \hat{\mathbf{Y}}_n(l). \quad (2.29)$$

Matriks varians-kovarians *error* peramalan adalah $\mathbf{\Omega}$. Jika \mathbf{Y}_t memiliki stasioneritas yang lemah, maka peramalan sebanyak l tahap ke depan atau $\hat{\mathbf{Y}}_{i,T}(l)$

akan konvergen menuju vektor rata-rata μ sebagai peningkatan peramalan pada waktu l .

2.3 Model *Space-Time Autoregressive* (STAR)

Model STAR diperkenalkan oleh Cliff dan Ord (1973). Sama halnya dengan model VAR, model STAR mempunyai karakteristik dependensi linier dalam lokasi dan waktu.

Jika diberikan $Y_t^{(i)}$ dengan $t = \{1, 2, \dots, n\}$ dan $i = \{1, 2, \dots, m\}$ merupakan indeks parameter waktu dan lokasi yang terhitung dan terbatas, maka model *Space-Time Autoregressive Moving Average* (STARMA) dari Pfeiffer dan Deustch (1980a) adalah

$$\mathbf{Y}_t = \sum_{k=1}^p \sum_{s=0}^{\lambda_p} \Phi_{ks} \mathbf{W}^{(s)} \mathbf{Y}_{t-k} - \sum_{k=1}^q \sum_{s=0}^{\lambda_q} \Theta_{ks} \mathbf{W}^{(s)} \mathbf{e}_{t-k} + \mathbf{e}_t, \quad (2.30)$$

Dengan Φ_{ks} dan Θ_{ks} adalah matriks regresi dan $\mathbf{W}^{(l)}$ adalah matriks bobot yang dipengaruhi oleh lokasi. Dalam hal ini, Pfeifer dan Deutsch memodelkan observasi di lokasi i pada saat t adalah kombinasi linier dari lokasi tersebut pada saat sebelumnya dan residual pada saat sebelumnya. Apabila orde $p=0$, maka model (2.30) menjadi model *Space-Time Moving Average* (STMA) dan jika orde $q=0$ menjadi model *Space-Time Autoregressive* (STAR).

Model STAR orde (p_1) , yang berarti orde spasial adalah 1 dan orde waktu adalah p , atau bisa ditulis $\text{STAR}(p_1)$ dari Pfeifer dan Deutsch (1980a) dirumuskan sebagai berikut,

$$\mathbf{Y}_t = \sum_{k=1}^p \left[\Phi_{k0} \mathbf{W}^{(0)} \mathbf{Y}_{t-k} + \Phi_{k1} \mathbf{W}^{(1)} \mathbf{Y}_{t-k} \right] + \mathbf{e}_t \quad (2.31)$$

dengan

Φ_{ks} = parameter STAR pada lag waktu (*time*) k dan lag spasial s ,

$\mathbf{W}^{(0)}$ = matriks identitas ukuran $(m \times m)$,

$\mathbf{W}^{(s)}$ = matriks bobot ukuran $(m \times m)$ pada lag spasial s (dengan $s=0,1$),

\mathbf{e}_t = vektor *noise* ukuran $(m \times 1)$ berdistribusi normal multivariat dengan *mean* nol dan matriks varians-kovarians $\sigma^2 \mathbf{I}_m$

\mathbf{Y}_t = vektor acak ukuran $(m \times 1)$ pada waktu t , yaitu $\mathbf{Y}_t = [Y_t^{(1)}, \dots, Y_t^{(m)}]'$.

Model sederhana AR berorde 1 dan spasial lag 1 atau STAR (1₁), dengan tiga lokasi ($m=3$), dinyatakan sebagai berikut,

$$\mathbf{Y}_t = \phi_{10} \mathbf{I}_3 \mathbf{Y}_{t-1} + \phi_{11} \mathbf{W}^{(1)} \mathbf{Y}_{t-1} + \mathbf{e}_t \quad (2.32)$$

Dari model (2.32), untuk tiga lokasi maka model di lokasi ke- m dapat dinyatakan sebagai berikut,

$$\begin{aligned} Y_t^{(1)} &= \phi_{10} Y_{t-1}^{(1)} + \phi_{11} w_{12} Y_{t-1}^{(2)} + \phi_{11} w_{13} Y_{t-1}^{(3)} + e_t^{(1)} \\ Y_t^{(2)} &= \phi_{10} Y_{t-1}^{(2)} + \phi_{11} w_{21} Y_{t-1}^{(1)} + \phi_{11} w_{23} Y_{t-1}^{(3)} + e_t^{(2)} \\ Y_t^{(3)} &= \phi_{10} Y_{t-1}^{(3)} + \phi_{11} w_{31} Y_{t-1}^{(1)} + \phi_{11} w_{32} Y_{t-1}^{(2)} + e_t^{(3)}. \end{aligned} \quad (2.33)$$

2.4 Model *Generalized Space-time Auto regressive* (GSTAR)

Model GSTAR merupakan generalisasi dari model *Space-time Autoregressive* (STAR) yang juga merupakan spesifikasi dari model *Vector Autoregressive* (VAR). Perbedaan model GSTAR dan model STAR terletak pada pengasumsian parameternya. Model STAR mengasumsikan lokasi-lokasi yang digunakan dalam penelitian sama, sehingga model ini hanya dapat diterapkan pada lokasi yang bersifat seragam. Sedangkan pada model GSTAR terdapat asumsi yang menyatakan lokasi-lokasi penelitian yang bersifat heterogen, sehingga perbedaan antar lokasi ini ditunjukkan dalam bentuk matriks pembobot.

Apabila diketahui suatu deret $\{\mathbf{Y}_t : t=0, \pm 1, \pm 2, \dots\}$, merupakan sebuah *time series multivariate* dari m pengamatan, maka persamaan model GSTAR untuk orde waktu $\text{AR}(p)$ dan spasial $(\lambda_1, \lambda_2, \dots, \lambda_p)$ (ditulis $\text{GSTAR}(p; \lambda_1, \lambda_2, \dots, \lambda_p)$) dapat ditulis sebagai berikut, (Wutsqa, Suhartono, dan Sutijo, 2010)

$$\mathbf{Y}_t = \sum_{k=1}^p \left[\Phi_{k0} + \sum_{s=1}^{\lambda_s} \Phi_{ks} \mathbf{W}^{(s)} \right] \mathbf{Y}_{t-k} + \mathbf{e}_t, \quad (2.34)$$

Model GSTAR pada persamaan (2.34) dengan orde waktu dan spasial satu dapat ditulis

$$\mathbf{Y}_t = \Phi_{10} \mathbf{Y}_{t-1} + \Phi_{11} \mathbf{W}^{(1)} \mathbf{Y}_{t-1} + \mathbf{e}_t \quad (2.35)$$

dengan

\mathbf{Y}_t = vektor random berukuran $(m \times 1)$ pada waktu t

$\Phi_{k0} = \text{diag}(\varphi_{k0}^1, \dots, \varphi_{k0}^m) = \text{matriks koefisien parameter waktu}$

$\Phi_{ks} = \text{diag}(\varphi_{ks}^1, \dots, \varphi_{ks}^m) = \text{matriks koefisien parameter spasial}$

$\mathbf{W}^{(s)} = \text{nilai matriks pembobot ukuran } (m \times m) \text{ pada lag spasial ke-} s.$

Nilai pembobot yang dipilih harus memenuhi syarat $w_{ii}^{(s)} = 0$ dan $\sum_{i \neq j} w_{ij}^{(s)} = 1$.

Serta \mathbf{e}_t adalah vektor *error* yang memenuhi asumsi identik, independen, dan berdistribusi normal multivariat dengan rata-rata $E[\mathbf{e}_t] = 0$ dan variansi $E[\mathbf{e}_t \mathbf{e}_t'] = \mathbf{\Omega}$. Bentuk matriks untuk persamaan (2.35) dengan menggunakan tiga lokasi yang berbeda dapat ditulis sebagai berikut,

$$\begin{bmatrix} y_t^{(1)} \\ y_t^{(2)} \\ y_t^{(3)} \end{bmatrix} = \begin{bmatrix} \varphi_{10} & 0 & 0 \\ 0 & \varphi_{20} & 0 \\ 0 & 0 & \varphi_{30} \end{bmatrix} \begin{bmatrix} y_{t-1}^{(1)} \\ y_{t-1}^{(2)} \\ y_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} \varphi_{11} & 0 & 0 \\ 0 & \varphi_{21} & 0 \\ 0 & 0 & \varphi_{31} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \begin{bmatrix} y_{t-1}^{(1)} \\ y_{t-1}^{(2)} \\ y_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} e_t^{(1)} \\ e_t^{(2)} \\ e_t^{(3)} \end{bmatrix}. \quad (2.36)$$

Dalam mengidentifikasi orde model GSTAR, orde spasial pada umumnya dibatasi pada orde 1 karena orde yang lebih tinggi akan sulit untuk diinterpretasikan (Suhartono & Wutsqa, 2010). Sedangkan orde waktu dapat ditentukan dengan menggunakan AIC (Wei, 2006). Akan tetapi penentuan orde model berdasarkan nilai AIC tidak dapat menangkap pola *seasonal*, oleh karena itu penentuan orde model juga dapat dilakukan berdasarkan *plot* MCCF dan MPCCF yang terbentuk (Suhartono & Wutsqa, 2010).

2.4.1 Pemilihan Bobot Lokasi pada Model GSTAR

Pemilihan pembobotan lokasi adalah salah satu permasalahan utama yang sering dihadapi pada penerapan pemodelan GSTAR. Misalkan diketahui tiga buah lokasi dengan posisi seperti pada Gambar 2.3, maka beberapa metode yang dapat digunakan untuk menentukan bobot dari peta lokasi di bawah antara lain adalah bobot seragam, invers jarak, dan normalisasi korelasi silang.



Gambar 2.3 Peta Lokasi Wilayah II KPW BI (Jawa Barat)

Metode yang digunakan sebagai pembobot lokasi dalam GSTAR adalah sebagai berikut.

1. Bobot Lokasi Seragam

Bobot lokasi seragam mengasumsikan bahwa lokasi-lokasi yang digunakan dalam penelitian bersifat homogen. Penentuan nilai bobot pada pembobotan ini adalah

$$w_{ij} = \frac{1}{n_i}, \quad (2.37)$$

dengan n_i merupakan banyaknya lokasi yang berdekatan dan w_{ij} merupakan bobot lokasi ke- i dan ke- j . Sehingga pada Gambar 2.3 matriks pembobot diberikan

$$\mathbf{W} = \begin{bmatrix} 0 & 1/2 & 1/2 \\ 1/2 & 0 & 1/2 \\ 1/2 & 1/2 & 0 \end{bmatrix}.$$

2. Bobot Lokasi Invers Jarak

Pembobotan dengan metode lokasi invers jarak dilakukan berdasarkan jarak sebenarnya antar lokasi dilapangan. Perhitungan bobot dengan metode ini diperoleh dari hasil invers jarak sebenarnya yang kemudian dinormalisasi. Berdasarkan Gambar 2.3 dapat dimisalkan perhitungan sebagai berikut,

$$w_{AB} = \frac{\frac{1}{d_{AB}}}{\frac{1}{d_{AB}} + \frac{1}{d_{AC}}} = \frac{\frac{1}{3}}{\frac{1}{3} + 1} = \frac{1}{4}; \quad w_{AC} = \frac{\frac{1}{d_{AC}}}{\frac{1}{d_{AC}} + \frac{1}{d_{AB}}} = \frac{1}{1 + \frac{1}{3}} = \frac{3}{4}$$

begitu juga dengan perhitungan bobot untuk lokasi-lokasi lainnya, sehingga matriks pembobot yang diperoleh dengan metode invers jarak adalah

$$\mathbf{W} = \begin{bmatrix} 0 & 1/4 & 3/4 \\ 2/5 & 0 & 3/5 \\ 2/3 & 1/3 & 0 \end{bmatrix}.$$

3. Bobot Lokasi Normalisasi Korelasi Silang

Pembobotan lokasi normalisasi korelasi silang menggunakan hasil normalisasi korelasi silang antar lokasi pada *lag* yang bersesuaian (Suhartono & Atok, 2006). Kemudian dikembangkan oleh Suhartono dan Subanar (2006) dengan menggunakan inferensia statistik terhadap korelasi silang untuk penentuan bobot lokasinya. Secara umum korelasi silang antara lokasi ke-*i* dan ke-*j* pada lag waktu ke-*k*, $\text{corr}[Y_t^{(i)}, Y_{t-k}^{(j)}]$, didefinisikan sebagai berikut,

$$\rho_k^{(ij)} = \frac{\gamma_k^{(ij)}}{\sigma^{(i)} \sigma^{(j)}}, \quad k = 0, \pm 1, \pm 2, \dots \quad (2.38)$$

dengan $\gamma_k^{(ij)}$ merupakan kovarians silang antara kejadian di lokasi ke-*i* dan ke-*j*, $\sigma^{(i)}$ dan $\sigma^{(j)}$ merupakan standar deviasi antar pengamatan di lokasi ke-*i* dan ke-*j*. Taksiran dari korelasi silang ini pada sampel dapat dihitung dengan persamaan berikut,

$$r_k^{(ij)} = \frac{\sum_{t=k+1}^n [Y_t^{(i)} - \bar{Y}^{(i)}][Y_{t-k}^{(j)} - \bar{Y}^{(j)}]}{\sqrt{\left(\sum_{t=k+1}^n [Y_t^{(i)} - \bar{Y}^{(i)}]^2 \right) \left(\sum_{t=k+1}^n [Y_{t-k}^{(j)} - \bar{Y}^{(j)}]^2 \right)}}. \quad (2.39)$$

Bartlett dalam Wei (2006) telah menurunkan varians dan kovarians dari besaran korelasi silang yang diperoleh dari sampel. Dibawah hipotesis bahwa dua data *time series* $Y^{(i)}$ dan $Y^{(j)}$ adalah tidak berkorelasi, menunjukkan bahwa

$$\text{Varians}[r_k^{(ij)}] \cong \frac{1}{n-k} \left[1 + 2 \sum_{s=1}^{\infty} \rho_s^{ii} \rho_s^{jj} \right]. \quad (2.40)$$

Oleh karena itu, ketika $Y^{(i)}$ dan $Y^{(j)}$ merupakan deret yang *white noise*, diperoleh

$$\text{Varians} \left[r_k^{ij} \right] \cong \frac{1}{n-k}. \quad (2.41)$$

Untuk ukuran sampel yang besar, $(n - k)$ dalam persamaan (2.41) sering kali diganti dengan n . Dibawah asumsi distribusi normal, maka nilai-nilai korelasi silang pada sampel ini dapat diuji apakah sama atau berbeda dengan nol. Uji hipotesis atau proses inferensia statistik dapat dilakukan menggunakan taksiran interval

$$r_k^{(ij)} \pm \left[t_{\alpha/2; n-k-2} \frac{1}{\sqrt{n}} \right]. \quad (2.42)$$

Penentuan bobot lokasi dapat dilakukan melalui normalisasi dari hasil besaran-besaran korelasi silang antar lokasi pada waktu yang bersesuaian. Proses ini secara umum menghasilkan bobot lokasi untuk model GSTAR(1₁), yaitu sebagai berikut,

$$w_k^{(ij)} = \frac{r_1^{(ij)}}{\sum_{k \neq i} |r_1^{(ik)}|}, \quad (2.43)$$

dengan $i \neq j$ dan bobot ini memenuhi $\sum_{i \neq j} |w^{(ij)}| = 1$. Bobot lokasi dengan menggunakan normalisasi dari hasil inferensia statistik terhadap korelasi silang antar lokasi pada lag waktu yang bersesuaian ini memungkinkan semua bentuk kesi silang mungkin hubungan antar lokasi. Bobot ini juga memberikan fleksibilitas pada besar dan tanda hubungan antar lokasi yang berlainan, yaitu positif dan negatif. Bobot lokasi ini mencakup bobot lokasi seragam dan biner (Suhartono dan Subanar, 2006).

2.4.2 Estimasi Parameter Model GSTAR

Pada penelitian ini digunakan 2 (dua) bentuk metode estimasi parameter pada model GSTAR, yaitu (i) *Ordinary Least Square* (OLS), dan (ii) *Generalized Least Square* (GLS). Berikut uraian dari masing-masing metode estimasi.

i. Estimasi metode OLS

Estimasi parameter dapat dilakukan dengan menggunakan metode *least square*, yaitu dengan meminimumkan jumlah kuadrat simpangannya (Borovkova,

Lopuhaa, dan Ruchjana, 2008). Dengan parameter regresi waktu Φ_{10} dan spasial Φ_{11} sama seperti pada persamaan (2.35) dimana $W^{(i)}$ menyatakan bobot lokasi yang satu terhadap lokasi lainnya, maka model GSTAR(1₁) dapat dinyatakan dalam matriks sebagai berikut,

$$\mathbf{Y}_t = \mathbf{A}\mathbf{Y}_{t-1} + \mathbf{e}_t \quad (2.44)$$

dengan $\mathbf{A} = \Phi_{10} + \Phi_{11}\mathbf{W}$ dimana Φ_{10} dan Φ_{11} merupakan matriks diagonal atas parameter autoregresi untuk waktu dan lokasi, dan \mathbf{W} merupakan matriks pembobot. Metode *least square* sering digunakan dalam melakukan penaksiran parameter terhadap suatu model linier. Metode ini dapat diterapkan pada model GSTAR (1₁). Struktur model linier dari GSTAR (1₁) dengan matriks desain acak dan kesalahan-kesalahan yang berkorelasi, yaitu (Lopuhaä, H.P., 2002)

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{e} \quad (2.45)$$

model pada persamaan (2.45) untuk lokasi ke- i dapat ditulis

$$\mathbf{Y}_i = \mathbf{X}_i\boldsymbol{\beta}_i + \mathbf{e}_i, \quad (2.46)$$

dengan $\boldsymbol{\beta}_i = (\phi_{i0}, \phi_{i1})'$, sehingga diperoleh bentuk matriks

$$\begin{bmatrix} y_1^{(i)} \\ y_2^{(i)} \\ \vdots \\ y_n^{(i)} \end{bmatrix} = \begin{bmatrix} y_0^{(i)} & V_0^{(i)} \\ y_1^{(i)} & V_1^{(i)} \\ \vdots & \vdots \\ y_{n-1}^{(i)} & y_{n-1}^{(i)} \end{bmatrix} \begin{bmatrix} \phi_0^{(i)} \\ \phi_1^{(i)} \end{bmatrix} + \begin{bmatrix} e_1^{(i)} \\ e_2^{(i)} \\ \vdots \\ e_n^{(i)} \end{bmatrix}, \quad (2.47)$$

dengan $y_t^{(i)}$ merupakan banyaknya pengamatan dimana $t=0,1,\dots,n$ untuk lokasi

$i=0,1,\dots,m$ dan $V_t^{(i)} = \sum_{j \neq i} w^{(ij)} \mathbf{Y}_t^{(j)}$ sehingga diperoleh bentuk matriks

$$\begin{bmatrix} y_1^{(1)} \\ y_2^{(1)} \\ \vdots \\ y_n^{(1)} \\ \vdots \\ y_1^{(m)} \\ y_2^{(m)} \\ \vdots \\ y_n^{(m)} \end{bmatrix} = \begin{bmatrix} y_0^{(1)} & V_0^{(1)} & \cdots & 0 & 0 \\ y_1^{(1)} & V_1^{(1)} & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ y_{n-1}^{(1)} & V_{n-1}^{(1)} & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & y_0^{(m)} & V_0^{(m)} \\ 0 & 0 & \cdots & y_1^{(m)} & V_1^{(m)} \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & y_{n-1}^{(m)} & V_{n-1}^{(m)} \end{bmatrix} \begin{bmatrix} \phi_{10} \\ \phi_{11} \\ \vdots \\ \phi_{m0} \\ \phi_{m1} \end{bmatrix} + \begin{bmatrix} e_1^{(1)} \\ e_2^{(1)} \\ \vdots \\ e_n^{(1)} \\ \vdots \\ e_1^{(m)} \\ e_2^{(m)} \\ \vdots \\ e_n^{(m)} \end{bmatrix}. \quad (2.48)$$

Hal ini berarti estimator *least square* untuk $\beta^{(i)}$ dapat dihitung secara terpisah pada masing-masing lokasi namun tetap bergantung pada nilai Y_t di lokasi yang lain dan persamaan (2.48), estimasi parameter model GSTAR(1₁) di tiga lokasi dapat disederhanakan menjadi

$$\begin{bmatrix} y_t^{(1)} \\ y_t^{(2)} \\ y_t^{(3)} \end{bmatrix} = \begin{bmatrix} \varphi_{10} y_{t-1}^{(1)} \\ \varphi_{20} y_{t-1}^{(2)} \\ \varphi_{30} y_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} \varphi_{11} (w_{12} y_{t-1}^{(2)} + w_{13} y_{t-1}^{(3)}) \\ \varphi_{21} (w_{21} y_{t-1}^{(1)} + w_{23} y_{t-1}^{(3)}) \\ \varphi_{31} (w_{31} y_{t-1}^{(1)} + w_{32} y_{t-1}^{(2)}) \end{bmatrix} + \begin{bmatrix} e_t^{(1)} \\ e_t^{(2)} \\ e_t^{(3)} \end{bmatrix}, \quad (2.49)$$

dengan $V_t^{(i)} = \sum_{j \neq i} w^{(ij)} Y_t^{(j)}$, sehingga menjadi

$$\begin{bmatrix} y_t^{(1)} \\ y_t^{(2)} \\ y_t^{(3)} \end{bmatrix} = \begin{bmatrix} y_{t-1}^{(1)} & 0 & 0 & V_{t-1}^{(1)} & 0 & 0 \\ 0 & y_{t-1}^{(2)} & 0 & 0 & V_{t-1}^{(2)} & 0 \\ 0 & 0 & y_{t-1}^{(3)} & 0 & 0 & V_{t-1}^{(3)} \end{bmatrix} \begin{bmatrix} \varphi_{10} \\ \varphi_{20} \\ \varphi_{30} \\ \varphi_{11} \\ \varphi_{21} \\ \varphi_{31} \end{bmatrix} + \begin{bmatrix} e_t^{(1)} \\ e_t^{(2)} \\ e_t^{(3)} \end{bmatrix}. \quad (2.50)$$

Berdasarkan matrik di atas, nilai taksiran untuk $\beta = (\varphi_{01}, \varphi_{11}, \varphi_{02}, \varphi_{12}, \dots, \varphi_{0m}, \varphi_{1m})'$ dengan $n \rightarrow \infty$, dapat dihitung menggunakan estimator *least square* menjadi $\hat{\beta}_T = (\hat{\varphi}_{01}, \hat{\varphi}_{11}, \hat{\varphi}_{02}, \hat{\varphi}_{12}, \dots, \hat{\varphi}_{0m}, \hat{\varphi}_{1m})'$ sehingga,

$$\begin{aligned} \mathbf{X}'\mathbf{X}\hat{\beta}_n &= \mathbf{X}'\mathbf{Y} \\ &= \mathbf{X}'(\mathbf{X}\beta + \mathbf{e}) \\ &= \mathbf{X}'\mathbf{X}\beta + \mathbf{X}'\mathbf{e} \end{aligned} \quad (2.51)$$

secara tidak langsung menyatakan $\mathbf{X}'\mathbf{X}(\hat{\beta}_n - \beta) = \mathbf{X}'\mathbf{e}$.

Elemen-elemen dari matriks $\mathbf{X}'\mathbf{X}$ adalah

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} \mathbf{X}^{(1)'}\mathbf{X}^{(1)} & 0 & \dots & 0 \\ 0 & \mathbf{X}^{(2)'}\mathbf{X}^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \mathbf{X}^{(m)'}\mathbf{X}^{(m)} \end{pmatrix}$$

$$\text{dimana } \mathbf{X}^{(i)'}\mathbf{X}^{(i)} = \begin{pmatrix} \sum_{t=0}^{n-1} [Y_t^{(i)}]^2 & \sum_{t=0}^{n-1} Y_t^{(i)} V_t^{(i)} \\ \sum_{t=0}^{n-1} Y_t^{(i)} V_t^{(i)} & \sum_{t=0}^{n-1} [V_t^{(i)}]^2 \end{pmatrix} \text{ dan } V_t^{(i)} = \sum_{j \neq i} w^{(ij)} Y_t^{(j)}.$$

Metode *least square* pada estimasi parameter model dapat dilakukan dengan meminimumkan fungsi $\mathbf{e} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$, dengan demikian hasil estimator $\boldsymbol{\beta}$ didapat sebagai berikut

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{Y}. \quad (2.52)$$

Elemen-elemen dari vektor $\mathbf{X}'\mathbf{e}$ dapat ditunjukkan pada persamaan matriks sebagai berikut

$$\begin{pmatrix} Y_0^{(1)} & \dots & Y_{n-1}^{(1)} & \dots & 0 & \dots & 0 \\ V_0^{(1)} & \dots & V_{n-1}^{(1)} & \dots & 0 & \dots & 0 \\ \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & \dots & Y_0^{(m)} & \dots & Y_{n-1}^{(m)} \\ 0 & \dots & 0 & \dots & V_0^{(m)} & \dots & V_{n-1}^{(m)} \end{pmatrix} \begin{pmatrix} e_1^{(1)} \\ e_2^{(1)} \\ \vdots \\ e_n^{(1)} \\ \vdots \\ e_1^{(m)} \\ e_2^{(m)} \\ \vdots \\ e_n^{(m)} \end{pmatrix}_{(mn \times 1)} = \begin{pmatrix} \sum_{t=0}^{n-1} Y_t^{(1)} e_{t+1}^{(1)} \\ \sum_{t=0}^{n-1} V_t^{(1)} e_{t+1}^{(1)} \\ \vdots \\ \sum_{t=0}^{n-1} Y_t^{(m)} e_{t+1}^{(m)} \\ \sum_{t=0}^{n-1} V_t^{(m)} e_{t+1}^{(m)} \end{pmatrix}.$$

Estimator *least square* tersebut ekivalen dengan

$$\frac{1}{n} \mathbf{X}'\mathbf{X}(\hat{\boldsymbol{\beta}}_n - \boldsymbol{\beta}) = \frac{1}{n} \mathbf{X}'\mathbf{e} \text{ atau } \hat{\boldsymbol{\beta}}_n - \boldsymbol{\beta} = \left(\frac{1}{n} \mathbf{X}'\mathbf{X} \right)^{-1} \left(\frac{1}{n} \mathbf{X}'\mathbf{e} \right) \text{ dimana,}$$

$$\frac{1}{n} \mathbf{X}'\mathbf{X} = \begin{pmatrix} \frac{1}{n} \mathbf{X}^{(1)'}\mathbf{X}^{(1)} & 0 & \dots & 0 \\ 0 & \frac{1}{n} \mathbf{X}^{(2)'}\mathbf{X}^{(2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \frac{1}{n} \mathbf{X}^{(m)'}\mathbf{X}^{(m)} \end{pmatrix}, \frac{1}{n} \mathbf{X}'\mathbf{e} = \begin{pmatrix} \frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(1)} e_{t+1}^{(1)} \\ \frac{1}{n} \sum_{t=0}^{n-1} V_t^{(2)} e_{t+1}^{(2)} \\ \vdots \\ \frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(m)} e_{t+1}^{(m)} \\ \frac{1}{n} \sum_{t=0}^{n-1} V_{t+1}^{(m)} e_{t+1}^{(m)} \end{pmatrix},$$

$$\frac{1}{n} \mathbf{X}^{(i)'} \mathbf{X}^{(i)} = \begin{pmatrix} \frac{1}{n} \sum_{t=0}^{n-1} [Y_t^{(i)}]^2 & \frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(i)} V_t^{(i)} \\ \frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(i)} V_t^{(i)} & \frac{1}{n} \sum_{t=0}^{n-1} [V_t^{(i)}]^2 \end{pmatrix}.$$

Dalam mempelajari $\frac{1}{n} \mathbf{X}' \mathbf{X}$ dan $\frac{1}{n} \mathbf{X}' \mathbf{e}$, maka terlebih dahulu diketahui rata-rata

dari $\frac{1}{n} \sum_{t=0}^{n-1} [Y_t^{(i)}]^2$, $\frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(i)} e_{t+1}^{(i)}$, $\frac{1}{n} \sum_{t=0}^{n-1} [V_t^{(i)}]^2$, $\frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(i)} V_t^{(i)}$, $\frac{1}{n} \sum_{t=0}^{n-1} V_t^{(i)} e_{t+1}^{(i)}$ dengan

$n \rightarrow \infty$, untuk $i = 1, 2, \dots, m$ serta $\frac{1}{n} \sum_{t=0}^{n-1} [V_t^{(i)}]^2 = \sum_{j \neq i} \sum_{k \neq i} w^{(ij)} w^{(ik)} \frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(j)} Y_t^{(k)}$

yang identik dengan $\frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(i)} V_t^{(i)}$ dan $\frac{1}{n} \sum_{t=0}^{n-1} Y_t^{(i)} e_{t+1}^{(i)}$.

ii. Estimasi metode GLS

Seemingly Unrelated Regression (SUR) merupakan sebuah pengembangan dari model regresi linier yang terdiri dari beberapa persamaan regresi, dimana setiap persamaan memiliki respon yang berbeda dan dimungkinkan memiliki prediktor yang berbeda-beda pula. Model SUR dikembangkan pertama kali oleh Zellner (1962). SUR merupakan suatu pemodelan yang mengakomodasi korelasi antar kesalahan-kesalahan persamaan. Model SUR memiliki matriks varians-kovarians antar persamaan untuk menunjukkan korelasi kesalahan antar persamaan. Jika matriks varians-kovarians tidak diketahui maka dilakukan estimasi matriks varians-kovarians dengan metode *Two Stage Aitken* (Zellner, 1962). Model SUR dengan m persamaan dimana untuk masing-masing persamaan terdiri dari p variabel prediktor dapat dituliskan

$$\begin{aligned} Y_t^{(1)} &= \beta_0^{(1)} + \beta_1^{(1)} X_{t,1}^{(1)} + \beta_{12}^{(1)} X_{t,2}^{(1)} + \dots + \beta_p^{(1)} X_{t,p}^{(1)} + e_t^{(1)} \\ Y_t^{(2)} &= \beta_0^{(2)} + \beta_1^{(2)} X_{t,1}^{(2)} + \beta_2^{(2)} X_{t,2}^{(2)} + \dots + \beta_p^{(2)} X_{t,p}^{(2)} + e_t^{(2)} \\ &\vdots \\ Y_t^{(m)} &= \beta_0^{(m)} + \beta_1^{(m)} X_{t,1}^{(m)} + \beta_2^{(m)} X_{t,2}^{(m)} + \dots + \beta_p^{(m)} X_{t,p}^{(m)} + e_t^{(m)}, \end{aligned} \tag{2.53}$$

dengan $t = 1, 2, \dots, n$ dimana n menyatakan banyaknya pengamatan. Model SUR secara umum sama seperti persamaan (2.46). Jika ditulis dalam bentuk matriks diberikan dengan

$$\begin{bmatrix} \mathbf{Y}^{(1)} \\ \mathbf{Y}^{(2)} \\ \vdots \\ \mathbf{Y}^{(m)} \end{bmatrix} = \begin{bmatrix} \mathbf{X}^{(1)} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \mathbf{X}^{(2)} & \dots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \dots & \mathbf{X}^{(m)} \end{bmatrix} \begin{bmatrix} \boldsymbol{\beta}^{(1)} \\ \boldsymbol{\beta}^{(2)} \\ \vdots \\ \boldsymbol{\beta}^{(m)} \end{bmatrix} + \begin{bmatrix} \mathbf{e}^{(1)} \\ \mathbf{e}^{(2)} \\ \vdots \\ \mathbf{e}^{(m)} \end{bmatrix}, \quad (2.54)$$

dengan $\mathbf{Y}^{(i)}$ merupakan vektor respon berukuran $(n \times 1)$, $\mathbf{X}^{(i)}$ merupakan matriks variabel independen berukuran $(n \times p)$, $\boldsymbol{\beta}^{(i)}$ merupakan vektor parameter berukuran $(p \times 1)$, dan $\mathbf{e}^{(i)}$ merupakan vektor residual berukuran $(n \times 1)$ saling berkorelasi. Sehingga dari persamaan (2.54) dapat diuraikan

$$\begin{bmatrix} y_1^{(1)} \\ y_2^{(1)} \\ \vdots \\ y_n^{(1)} \\ y_1^{(2)} \\ y_2^{(2)} \\ \vdots \\ y_n^{(2)} \\ \vdots \\ y_1^{(m)} \\ y_2^{(m)} \\ \vdots \\ y_n^{(m)} \end{bmatrix} = \begin{bmatrix} \begin{bmatrix} 1 & x_{1,1}^{(1)} & x_{1,2}^{(1)} & \dots & x_{1,p}^{(1)} \\ 1 & x_{2,1}^{(1)} & x_{2,2}^{(1)} & \dots & x_{2,p}^{(1)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n,1}^{(1)} & x_{n,2}^{(1)} & \dots & x_{n,p}^{(1)} \end{bmatrix} & \mathbf{0} & \dots & \mathbf{0} \\ \mathbf{0} & \begin{bmatrix} 1 & x_{1,1}^{(2)} & x_{1,2}^{(2)} & \dots & x_{1,p}^{(2)} \\ 1 & x_{2,1}^{(2)} & x_{2,2}^{(2)} & \dots & x_{2,p}^{(2)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n,1}^{(2)} & x_{n,2}^{(2)} & \dots & x_{n,p}^{(2)} \end{bmatrix} & \dots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \end{bmatrix} \begin{bmatrix} \beta_0^{(1)} \\ \beta_1^{(1)} \\ \vdots \\ \beta_p^{(1)} \\ \beta_0^{(2)} \\ \beta_1^{(2)} \\ \vdots \\ \beta_p^{(2)} \\ \vdots \\ \beta_0^{(m)} \\ \beta_1^{(m)} \\ \vdots \\ \beta_p^{(m)} \end{bmatrix} + \begin{bmatrix} e_1^{(1)} \\ e_2^{(1)} \\ \vdots \\ e_n^{(1)} \\ e_1^{(2)} \\ e_2^{(2)} \\ \vdots \\ e_n^{(2)} \\ \vdots \\ e_1^{(m)} \\ e_2^{(m)} \\ \vdots \\ e_n^{(m)} \end{bmatrix}. \quad (2.55)$$

Asumsi yang harus dipenuhi dalam persamaan model SUR adalah $E(\mathbf{e}) = \mathbf{0}$ dan $E(\mathbf{e}^{(i)} \mathbf{e}^{(j) \prime}) = \boldsymbol{\sigma}^{(ij)} \mathbf{I}$. Zellner (1962) mengasumsikan bahwa struktur matriks varians-kovarians pada sistem persamaan model SUR diberikan dengan

$$E[\mathbf{e}^{(i)} \mathbf{e}^{(j) \prime}] = \begin{bmatrix} e^{(1)} \\ e^{(2)} \\ \vdots \\ e^{(m)} \end{bmatrix} \begin{bmatrix} e^{(1)} & e^{(2)} & \dots & e^{(m)} \end{bmatrix} \quad (2.56)$$

persamaan (2.56) apabila diuraikan menjadi

$$E[\mathbf{e}^{(i)} \mathbf{e}^{(j)'}] = \begin{bmatrix} E(e^{(1)} e^{(1)}) & E(e^{(1)} e^{(2)}) & \dots & E(e^{(1)} e^{(m)}) \\ E(e^{(2)} e^{(1)}) & E(e^{(2)} e^{(2)}) & \dots & E(e^{(2)} e^{(m)}) \\ \vdots & \vdots & \ddots & \vdots \\ E(e^{(m)} e^{(1)}) & E(e^{(m)} e^{(2)}) & \dots & E(e^{(m)} e^{(m)}) \end{bmatrix} \quad (2.57)$$

karena $E(\mathbf{e}^{(i)} \mathbf{e}^{(j)'}) = \boldsymbol{\sigma}^{(ij)} \mathbf{I}$ sehingga dapat dituliskan

$$E[\mathbf{e}^{(i)} \mathbf{e}^{(j)'}] = \begin{bmatrix} \sigma^{(11)} \mathbf{I} & \sigma^{(12)} \mathbf{I} & \dots & \sigma^{(1m)} \mathbf{I} \\ \sigma^{(21)} \mathbf{I} & \sigma^{(22)} \mathbf{I} & \dots & \sigma^{(2m)} \mathbf{I} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma^{(m1)} \mathbf{I} & \sigma^{(m1)} \mathbf{I} & \dots & \sigma^{(mm)} \mathbf{I} \end{bmatrix} \quad (2.58)$$

persamaan (2.58) apabila diuraikan dengan perkalian Kronecker (\otimes) menjadi

$$\begin{aligned} E[\mathbf{e}^{(i)} \mathbf{e}^{(j)'}] &= \begin{bmatrix} \sigma^{(11)} & \sigma^{(12)} & \dots & \sigma^{(1m)} \\ \sigma^{(21)} & \sigma^{(22)} & \dots & \sigma^{(2m)} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma^{(m1)} & \sigma^{(m1)} & \dots & \sigma^{(mm)} \end{bmatrix} \otimes \mathbf{I} \\ &= \boldsymbol{\Sigma} \otimes \mathbf{I} \\ &= \boldsymbol{\Omega}, \end{aligned} \quad (2.59)$$

$$\text{dengan } \boldsymbol{\Sigma} = \begin{bmatrix} \sigma^{(11)} & \sigma^{(12)} & \dots & \sigma^{(1m)} \\ \sigma^{(21)} & \sigma^{(22)} & \dots & \sigma^{(2m)} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma^{(m1)} & \sigma^{(m2)} & \dots & \sigma^{(mm)} \end{bmatrix} \text{ dan } \mathbf{I} = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}$$

$\boldsymbol{\Sigma}$ merupakan matriks varians-kovarians *error* berukuran $(m \times m)$ dan \mathbf{I} merupakan matriks identitas berukuran $(n \times n)$.

Salah satu pendekatan yang dapat digunakan dalam mengestimasi parameter model SUR adalah metode GLS (Baltagi, 1980) yang merupakan pengembangan dari OLS. Jika proses estimasi parameter pada OLS dilakukan dengan cara meminimumkan fungsi persamaan (2.51), maka untuk GLS dapat dikembangkan dengan cara meminimumkan fungsi $\mathbf{e}'\mathbf{e} = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})' \boldsymbol{\Omega}^{-1} (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})$.

Sehingga estimator untuk $\boldsymbol{\beta}$ diberikan dengan

$$\hat{\beta} = (\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{X})^{-1}\mathbf{X}'\mathbf{\Omega}^{-1}\mathbf{Y}. \quad (2.60)$$

2.4.3 Kondisi Stasioner Parameter Model GSTAR

Borovkova dkk. (2002) dan Ruchjana (2002) menyatakan bahwa model GSTAR khususnya GSTAR(1₁) merupakan versi yang terbatas dari model VAR. Oleh karena itu, kondisi stasioner model GSTAR dapat diperoleh dari kondisi stasioner model VAR. Model GSTAR(1₁), $\mathbf{Y}_t = \Phi_{10} + \Phi_{11}\mathbf{W}^{(1)}\mathbf{Y}_{t-1} + \mathbf{e}_t$ dapat diwakili dengan model VAR(1), $\mathbf{Y}_t = \Phi_1\mathbf{Y}_{t-1} + \mathbf{e}_t$, dengan

$$\Phi_1 = [\Phi_{10} + \Phi_{11}\mathbf{W}^{(1)}] \quad (2.61)$$

secara umum model GSTAR yang merupakan proses stasioner adalah jika semua *eigenvalue* dari matriks $[\Phi_{10} + \Phi_{11}\mathbf{W}^{(1)}]$ memenuhi syarat $|\lambda| < 1$.

Suhartono dan Subanar (2007) menyatakan bahwa kondisi stasioner pada model GSTAR, khususnya untuk parameter pada model GSTAR(1₁) dapat menggunakan syarat $|\lambda| < 1$ yang disajikan dalam model VAR(1). Oleh karena itu, untuk mengecek kondisi stasioner parameter model GSTAR(1₁) harus disajikan dalam bentuk VAR(1) terlebih dahulu.

2.5 Peramalan Model *Multivariate Time Series*

Model yang didapatkan kemudian digunakan untuk peramalan. Peramalan berikut ini digunakan dengan mengasumsikan model telah diketahui dan mengabaikan sementara jika parameter telah dilakukan estimasi.

Misal *time series* univariat, $\hat{Y}_n(l)$ adalah hasil ramalan l tahap ke depan dari Y_{n+l} yang mengikuti model ARMA(1,1). Model ARMA(1,1) dapat dituliskan sebagai berikut, (Wei, 2006)

$$(1 - \phi_1 B)(Y_t - \mu) = (1 - \theta_1 B)a_t \quad (2.62)$$

persamaan (2.62) dapat dihitung ramalan $\hat{Y}_n(l)$ untuk kondisi yang diekspektasikan dari nilai yang berbeda, misal untuk $t = n + l$, sehingga didapat persamaan sebagai berikut,

$$Y_{n+l} = \mu + \varphi_1(Y_{n+l-1} - \mu) + a_{n+l} - \theta_1 a_{n+l-1} \quad (2.63)$$

karena,

$$\hat{Y}_n(1) = \mu + \varphi_1(Y_n - \mu) - \theta_1 a_n \quad (2.64)$$

dan persamaan peramalan untuk l tahap ke depan dapat ditulis sebagai berikut,

$$\begin{aligned} \hat{Y}_n(l) &= \mu + \varphi_1(\hat{Y}_n(l-1) - \mu) \\ &= \mu + \varphi_1^l[Y_n - \mu] - \varphi_1^{l-1}\theta_1 a_n, l \geq 2 \end{aligned} \quad (2.65)$$

Sedangkan bentuk umum peramalan model GSTAR dapat ditulis seperti persamaan berikut,


$$\hat{\mathbf{Y}}_t = \sum_{k=1}^p \left[\Phi_{k0} \mathbf{Y}_{t-k} + \sum_{s=1}^{\lambda_s} \Phi_{ks} \mathbf{W}^{(s)} \mathbf{Y}_{t-k} \right]. \quad (2.66)$$

2.6 Model Support Vector Machine

Support Vector Machine adalah suatu teknik baru untuk melakukan prediksi, baik dalam skenario klasifikasi maupun regresi, yang sangat populer belakangan ini. Para ilmuwan dan praktisi telah banyak menerapkan teknik ini dalam menyelesaikan masalah-masalah yang nyata dalam kehidupan sehari-hari. Baik dalam bidang finansial, cuaca, hingga kedokteran terbukti dalam banyak implementasi SVM memberi hasil yang lebih baik dari NN terutama dalam hal solusi yang dicapai (Santosa, 2007). SVM melakukan suatu teknik untuk menemukan fungsi pemisah (*clasiffier*) yang bisa memisahkan dua set data dari dua kelas yang berbeda (Vapnik, 1998). Konsep dasar dari *Support Vector Machine* sebenarnya merupakan penggabungan dari teori-teori komputasi yang telah ada seperti *hyperplane*, kernel, dan konsep-konsep pendukung lain. Konsep ini diperkenalkan oleh Boser, Vapnik, dan Guyon pada tahun 1992. Pada penelitian sebelumnya SVM memberikan nilai ketepatan klasifikasi yang tinggi. SVM adalah *learning system* yang menggunakan ruang hipotesis berupa fungsi-fungsi linier dalam sebuah ruang fitur (*feature space*) berdimensi tinggi, dilatih dengan algoritma pembelajaran yang didasarkan pada teori optimasi dengan mengimplementasikan learning bias.

SVM berada dalam satu kelas *Neural Networks*, pada *Neural Networks* menemukan solusi beberapa lokal optimal dan SVM menemukan solusi yang

global optimal yaitu menghasilkan solusi yang sama pada setiap runningnya. Metode ini merupakan metode *learning machine* yang bekerja atas prinsip *Structural Risk Minimization (SRM)* dengan tujuan menemukan *hyperplane* terbaik yang memisahkan dua buah kelas pada *input space* (A.S.Nugroho, A.B.Witarto, & Handoko, 2003). SVM berada dalam kelas *supervised learning*.



Gambar 2.4 Batas Keputusan untuk Set Data


Pada Gambar 2.4 diperlihatkan beberapa data yang merupakan anggota dua kelas, yaitu kelas untuk laki-laki dan perempuan. Kelas laki-laki dinotasikan dengan +1 dan kelas perempuan dinotasikan dengan -1. Data yang termasuk dalam kelas perempuan disimbolkan dengan lingkaran. Proses pembelajaran problem klasifikasi diterjemahkan untuk menemukan garis *hyperplane* yang memisahkan antara dua kelas tersebut. Pada Gambar 2.4 (a) terlihat alternatif garis pemisah (*discrimination boundaries*), sedangkan pada Gambar 2.4 (b) ditunjukkan bahwa terdapat garis *hyperplane* yang tepat berada diantara dua kelas. Prinsip dasar dari analisis ini adalah menemukan *hyperplane* terbaik dengan meminimalkan kesalahan klasifikasi dan memaksimalkan *margin* geometriknya seperti pada Gambar 2.4 (b) (Prasetyo, 2014).

Dalam SVM bobot (w) dan bias (b) merupakan solusi global optimum dari *quadratic programming* yang merupakan formulasi matematika dari SVM sehingga cukup dengan sekali *running* akan menghasilkan solusi yang akan selalu sama untuk pilihan kernel dan parameter yang sama (Nurhayati dkk, 2015). Terdapat dua jenis data yang dapat diklasifikasikan dengan menggunakan SVM, yang pertama adalah *linearly separable data* yaitu data yang tidak dapat dipisahkan secara linier dan *nonlinearly separable data* yaitu data yang tidak dapat

dipisahkan secara non linier. SVM sendiri sebenarnya pertama kali diperkenalkan oleh Vapnik hanya dapat mengklasifikasikan data kedalam dua kelas. Akan tetapi dengan diadakannya pengembangan lebih lanjut, maka saat ini SVM telah dapat digunakan untuk mengklasifikasikan data lebih dari dua kelas.

2.6.1 Support Vector Regression (SVR)

SVR merupakan suatu model dan pengembangan dari SVM untuk pemodelan regresi dan *time series*. SVM untuk permasalahan regresi, memperkenalkan alternatif *loss function*. *Loss function* harus dimodifikasi ke dalam ukuran jarak. Gambar 2.5 mengilustrasikan empat kemungkinan *loss function*.




Gambar 2.5 *Loss Function*

Loss function pada Gambar 2.5(a) dapat disamakan dengan kriteria *least square error* konvensional. *Loss function* pada Gambar 2.5(b) adalah *Laplacian loss function* yang kurang sensitif terhadap outlier dibandingkan *loss function* kuadratik. Huber menawarkan *loss function* pada Gambar 2.5(c) sebagai *robust loss function* yang memiliki sifat optimal ketika distribusi data tidak diketahui. Ketiga *loss function* ini akan menghasilkan *support vector* (SV) yang tidak menyebar. Untuk mengatasi persoalan tersebut, Vapnik menawarkan *loss function* pada Gambar 2.5(d) sebagai pendekatan pada *loss function* Huber yang memungkinkan

untuk mendapatkan kumpulan *support vector* yang tersebar (Gunn & Steve, 1998).

Konsep SVM menggunakan konsep ϵ -insensitive loss function yang dapat digeneralisasi untuk melakukan pendekatan fungsi yang dikenal dengan SVR (Gunn, 1998). Konsep SVM menggunakan *hyperplane* tunggal pada ruang berdimensi banyak yang pada akhirnya partisi-partisi tersebut dapat diselesaikan secara non linier. Konsep SVR didasarkan pada *structural risk minimization*, yaitu untuk mengestimasi suatu fungsi dengan cara meminimalkan batas atas dari *generalization error*, sehingga SVR mampu mengatasi *overfitting*. Tujuan dari SVR adalah untuk mendapatkan suatu fungsi dengan tingkat kesalahan paling kecil sehingga menghasilkan suatu prediksi yang bagus. Ide dasar dari SVR yaitu dengan menentukan set data yang dibagi menjadi set *training* dan set *testing*. Kemudian dari set *training* tersebut ditentukan suatu fungsi regresi dengan batasan deviasi tertentu sehingga dapat menghasilkan prediksi yang mendekati dari target aktual.

Pada Gambar 2.6 (a) menunjukkan bagaimana *error* pada SVR dihitung. Sampai dengan garis batas *error* ϵ , nilai *error* dianggap sama dengan 0, sedangkan di luar batas tersebut nilai *error* akan dihitung sebagai ξ atau ξ^* . Solusi pada masalah ini adalah dari sebuah garis, akan dibentuk sebuah tabung yang memiliki toleransi terhadap *error* seperti yang ditunjukkan pada Gambar 2.6 (b).



Gambar 2.6 Batas *Error* dalam SVR

Mempertimbangkan masalah penaksiran, pasangan data sebanyak l pengamatan adalah sebagai berikut,

$$(y_1, x_1), \dots, (y_l, x_l), \mathbf{x} \in R^n, \mathbf{y} \in R \quad (2.73)$$

Fungsi regresi dari metode SVR akan sempurna apabila batas deviasinya (ε) sama dengan 0 sehingga dapat dituliskan sebagai berikut,

$$f(\mathbf{x}) = \mathbf{w}^T \varphi(\mathbf{x}) + b \quad (2.74)$$

dengan

\mathbf{w} = *vector* pembobot

$\varphi(\mathbf{x})$ = fungsi yang memetakan x dalam suatu dimensi

b = bias.

Simbol $\varphi(\mathbf{x})$ menunjukkan suatu titik di dalam *feature space* F yang merupakan hasil pemetaan \mathbf{x} di dalam *input space*. Koefisien \mathbf{w} dan b di sini berfungsi untuk meminimalkan fungsi resiko. Dengan meminimalkan fungsi resiko tersebut akan membuat suatu fungsi menjadi setipis mungkin, sehingga kapasitas fungsi dapat terkontrol, hal ini dinamakan regularisasi. Koefisien \mathbf{w} dan b diestimasi dengan cara meminimalkan fungsi resiko (*risk function*) yang didefinisikan dalam persamaan sebagai berikut,

$$R(f(\mathbf{x})) = \frac{C}{n} \sum_{t=1}^n L_\varepsilon(\mathbf{y}_t, f(\mathbf{x}_t)) + \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.75)$$

dimana

$$L_\varepsilon(\mathbf{y}_t, f(\mathbf{x}_t)) = \begin{cases} 0, & \text{untuk } |\mathbf{y}_t - f(\mathbf{x}_t)| - \varepsilon \\ |\mathbf{y}_t - f(\mathbf{x}_t)| - \varepsilon, & \text{lainnya} \end{cases} \quad (2.76)$$

dengan $L_\varepsilon(\mathbf{y}_t, f(\mathbf{x}_t))$ merupakan ε - *insensitive loss function*, \mathbf{y}_t adalah vektor dari nilai sebenarnya, C dan ε merupakan *hyper-parameter* yang sudah ditentukan.

Fungsi f diasumsikan dapat mengaproksimasi semua titik $(\mathbf{x}_t, \mathbf{y}_t)$ dengan presisi ε , jika semua titik berada dalam rentang $f \pm \varepsilon$ atau disebut *feasible*. Sedangkan *infeasible* merupakan kondisi dimana ada beberapa titik yang berada diluar rentang $f \pm \varepsilon$. Titik-titik yang *infeasible* bisa ditambahkan variabel

slack ξ^*, ξ untuk mengatasi *infeasible constrain*. Sehingga optimasi pada persamaan (2.75) dapat ditransformasi kedalam bentuk berikut,

$$\min \frac{1}{2} \|\mathbf{w}\|^2 + C \frac{1}{n} \sum_{t=1}^n (\xi_t + \xi_t^*) \quad (2.77)$$

dengan batasan

$$w\varphi(\mathbf{x}_t) + b - \mathbf{y}_t \leq \varepsilon + \xi_t^*$$

$$\mathbf{y}_t - w\varphi(\mathbf{x}_t) - b \leq \varepsilon + \xi_t^*$$

$$\xi_t, \xi_t^* \geq 0, \quad t = 1, 2, \dots, n$$

Optimalisasi pada batasan tersebut bisa diselesaikan menggunakan *primal lagrangian* dalam bentuk sebagai berikut, (Hong, 2008)

$$\begin{aligned} L(w, b, \xi, \xi^*, \alpha_t, \alpha_t^*, \beta_t, \beta_t^*) = & \frac{1}{2} \|\mathbf{w}\|^2 + C \left[\sum_{t=1}^n (\xi_t + \xi_t^*) \right] + \\ & - \sum_{t=1}^n \beta_t \left[w\varphi(\mathbf{x}_t) + b - \mathbf{y}_t + \varepsilon + \xi_t^* \right] + \\ & - \sum_{t=1}^n \beta_t^* \left[\mathbf{y}_t - w\varphi(\mathbf{x}_t) - b + \varepsilon + \xi_t^* \right] + \\ & - \sum_{t=1}^n (\alpha_t \xi_t + \alpha_t^* \xi_t^*) \end{aligned} \quad (2.78)$$

persamaan (2.78) diminimalkan pada variabel primal w, b, ξ, ξ^* dan dimaksimal-kan dalam bentuk *lagrangian multiplier nonnegative* $\alpha_t, \alpha_t^*, \beta_t, \beta_t^*$ seperti ditampilkan pada persamaan berikut (Hong, 2008)

$$\frac{\partial L}{\partial w} = w - \sum_{t=1}^n (\beta_t - \beta_t^*) \varphi(\mathbf{x}_t) = 0 \quad (2.79)$$

$$\frac{\partial L}{\partial b} = \sum_{t=1}^n (\beta_t^* - \beta_t) = 0 \quad (2.80)$$

$$\frac{\partial L}{\partial \xi} = C - \beta_t - \alpha_t = 0 \quad (2.81)$$

$$\frac{\partial L}{\partial \xi^*} = C - \beta_t^* - \alpha_t^* = 0 \quad (2.82)$$

Sehingga kondisi Karush-Kuhn-Tucker terapkan untuk model regresi dan dengan menggunakan persamaan (2.77) didapatkan *dual lagrangian* pada persamaan (2.74) dengan mensubstitusikan persamaan (2.79), (2.80), (2.81), dan

(2.82). Persamaan *dual lagrangian* didapatkan ketika fungsi kernel $K(\mathbf{x}_t, \mathbf{x}_u) = \varphi(\mathbf{x}_t)\varphi(\mathbf{x}_u)$.


Fungsi $K(\mathbf{x}_t, \mathbf{x}_u)$ merupakan fungsi kernel. Banyak teknik *data mining* yang dikembangkan untuk fungsi linier. Secara umum, skenario-skenario di dunia nyata merupakan skenario yang tidak linier. Dengan metode Kernel suatu data x pada *input space* di-mapping ke *feature space* F dengan dimensi yang lebih tinggi melalui map φ sebagai berikut,

$$\varphi : \mathbf{x} \rightarrow \varphi(\mathbf{x}) \quad (2.83)$$

Oleh karena itu, data x pada *input space* menjadi $\varphi(\mathbf{x})$ di *feature space*.

Fungsi yang digunakan untuk metode SVR adalah sebagai berikut.

1. Linier : $K(\mathbf{x}, \mathbf{x}^T) = \mathbf{x}^T \mathbf{x}$
2. Polinomial : $K(\mathbf{x}, \mathbf{x}^T) = (\mathbf{x}^T \mathbf{x} + 1)^p$
3. *Radial basis function* (RBF) : $K(\mathbf{x}_t, \mathbf{x}_u) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_t - \mathbf{x}_u\|^2\right)$



Gambar 2. 7 Grafik Fungsi Kernel Linier, Polinomial dan RBF

Pemilihan fungsi Kernel yang tepat merupakan hal yang sangat penting karena akan menentukan *feature space* dimana fungsi *classifier* akan dicari. Sepanjang fungsi Kernelnya *legitimate*, SVR akan beroperasi secara benar meskipun tidak mengetahui mapping yang digunakan (Santosa, 2007). Salah satu fungsi kernel yang paling sering digunakan adalah *Gaussian Radial Basis*

Function (RBF) seperti pada persamaan (2.84) (Haerdle, Prastyo, dan Hafner, 2014)

$$K(\mathbf{x}_t, \mathbf{x}_u) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}_t - \mathbf{x}_u\|^2\right) \quad (2.84)$$

$$\begin{aligned} \partial(\beta_t, \beta_t^*) = & \sum_{t=1}^n \mathbf{y}_t (\beta_t - \beta_t^*) - \varepsilon \sum_{t=1}^n (\beta_t + \beta_t^*) + \\ & - \frac{1}{2} \sum_{t,u=1}^n (\beta_t - \beta_t^*) (\beta_u - \beta_u^*) K(\mathbf{x}_t, \mathbf{x}_u) \end{aligned} \quad (2.85)$$

dengan batasan,

$$\begin{aligned} \sum_{t=1}^n (\beta_t - \beta_t^*) &= 0 \\ 0 \leq \beta_t &\leq C, \quad t = 1, 2, \dots, n \\ 0 \leq \beta_t^* &\leq C, \quad t = 1, 2, \dots, n. \end{aligned}$$

Lagrange Multipliers pada persamaan (2.85) memenuhi persamaan $\beta_t \cdot \beta_t^* = 0$. *Lagrange Multipliers* β_t dan β_t^* dihitung dan vektor bobot optimal yang diharapkan dari *hyperplane* regresi adalah sebagai berikut,

$$\mathbf{w}^* = \sum_{t=1}^n (\beta_t - \beta_t^*) \varphi(\mathbf{x}), \quad (2.86)$$

sehingga didapatkan fungsi regresi

$$f(\mathbf{x}, \beta_t, \beta_t^*) = \sum_{t=1}^n (\beta_t - \beta_t^*) K(\mathbf{x}_t, \mathbf{x}) + b. \quad (2.87)$$

Tidak seperti *loss function* kuadratik dan Huber, dimana semua titik data akan menjadi *support vektor*, ε -insensitive *loss function* ini menarik karena pada ε -insensitive *loss function* solusi SV dapat menyebar.

2.7 Pemilihan Model Terbaik

Pemilihan model terbaik menggunakan kriteria nilai RMSE *in-sample* dan *out-sample* dengan membandingkan nilai *multivariate Root Mean Square Error* (RMSE) terkecil pada model. RMSE *in-sample* dari suatu model dapat diperoleh melalui perhitungan sebagai berikut (Wei, 2006)

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (2.88)$$

dimana n merupakan banyaknya data *in-sample*, Y_t menyatakan data *in-sample* ke- t , dan \hat{Y}_t merupakan data hasil ramalan ke- t . Sedangkan untuk data *out-sample* nilai RMSE dirumuskan seperti berikut (Wei, 2006)

$$\text{RMSE} = \sqrt{\text{MSE}} = \sqrt{\frac{1}{m} \sum_{l=1}^m (Y_{n+l} - \hat{Y}_n(l))^2} \quad (2.89)$$

Dengan m merupakan banyaknya ramalan yang dilakukan, Y_l menyatakan data *out-sample* ke- l , dan \hat{Y}_l merupakan data hasil ramalan ke- l . Pemilihan model terbaik juga menggunakan nilai AIC, dengan persamaan sebagai berikut

$$\text{AIC}(p) = n \ln(|\mathbf{S}_p|) + 2pv^2 \quad (2.90)$$

dimana p adalah banyak parameter, v adalah banyaknya variabel, dan $|\mathbf{S}_p|$ adalah determinan dari *residual sum of square* dan perkalian silangnya,

$$\mathbf{S}_p = \sum_{t=p+1}^n (Y_t - \hat{\tau} - \hat{\Phi}_1 Y_{t-1} - \dots - \hat{\Phi}_p Y_{t-p}) \times (Y_t - \hat{\tau} - \hat{\Phi}_1 Y_{t-1} - \dots - \hat{\Phi}_p Y_{t-p})' \quad (2.91)$$

dimana $\hat{\tau}$ merupakan vektor konstan.

2.8 Pengedaran Uang di Indonesia

Uang Beredar adalah kewajiban sistem moneter (Bank Sentral, Bank Umum, dan Bank Perkreditan Rakyat/BPR) terhadap sektor swasta domestik (tidak termasuk pemerintah pusat dan bukan penduduk). Pada Juli 2013 dilakukan perluasan cakupan institusi yang menjadi bagian dari sistem moneter melalui penambahan BPR Syariah, sehingga sistem moneter mencakup institusi Bank Sentral, Bank Umum Konvensional dan Syariah serta BPR Konvensional dan Syariah. Penyempurnaan tersebut diterapkan mulai data periode Januari 2012.

Data uang kartal yang beredar di masyarakat disusun dari EDW SIPU yang direkonsiliasi dengan Posisi Neraca Bank Indonesia, sedangkan data *outflow* dan *inflow* bersumber dari Laporan Bulanan yang disampaikan oleh seluruh Satuan Kerja di Bank Indonesia dan EDW SIPU. Di Indonesia, kebijakan pengedaran uang dilakukan oleh Bank Indonesia yang kewenangannya diatur dalam Undang-Undang No. 23 Tahun 1999 tentang Bank Indonesia. Salah satu

dasar pembuatan Rencana Kebutuhan Uang (RKU) Bank Indonesia adalah data historis aliran uang masuk (*inflow*) dan aliran uang keluar (*outflow*). Pada RKU 2011 ditetapkan sebesar Rp 177,7 triliun atau meningkat sebesar 22,4% dari tahun 2010. Atas dasar RKU tersebut, Direktorat Pengedaran Uang (DPU) BI menetapkan Rencana Cetak Uang (RCU). Jumlah uang yang tertera pada RCU inilah yang nantinya akan diedarkan di masyarakat melalui Kantor Bank Indonesia (KBI) di berbagai wilayah.

Uang kartal yang beredar dimasyarakat dan perbankan (UYD) adalah uang kertas, uang logam, dan uang khusus yang dikeluarkan oleh otoritas moneter sebagai alat pembayaran yang sah. Perhitungan UYD diperoleh dari selisih antara posisi Rekening Pembuatan Uang (RPU) dengan posisi Rekening Kas di BI, Rekening Uang yang Dicabut dan Ditarik dari Peredaran (RUDDP), serta Rekening Uang dalam Penelitian (RUP). Rencana Distribusi Uang (RDU) adalah penetapan jumlah dan komposisi pecahan uang yang akan dikirim untuk memenuhi kebutuhan kas setiap kantor Bank Indonesia selama satu tahun. Dalam penyusunan RDU terdapat beberapa faktor yang dijadikan pertimbangan, yaitu : (i) jumlah setoran (*inflow*) dan bayaran (*outflow*) ; (ii) uang yang dimusnahkan (PTTB) ; (iii) jumlah posisi kas; dan (iv) kondisi ekonomi serta geografis daerah secara spesifik. Perkembangan *inflow* dan *outflow*, baik di Jakarta maupun di daerah, sesungguhnya mencerminkan suatu pola pergerakan permintaan uang kartal yang dipengaruhi oleh faktor pertumbuhan ekonomi, perkembangan inflasi, perbandingan jumlah kredit dan dana, jumlah kantor bank & jaringan ATM, perkembangan suatu daerah (termasuk otonomi daerah), faktor musiman, tingkat usia edar uang dan jarak suatu daerah dari Jakarta.

Transaksi penyetoran uang rupiah (*inflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang masuk dari perbankan dan masyarakat ke Bank Indonesia, terdiri dari setoran bank umum, setoran non-bank, kas keliling dalam rangka hasil penukaran, penyetoran dalam rangka kas titipan di bank umum, dan penyetoran lainnya. Transaksi penarikan uang rupiah (*outflow*) merupakan informasi mengenai aliran uang kertas dan uang logam yang keluar dari Bank Indonesia kepada perbankan dan masyarakat, terdiri dari penarikan bank umum, penarikan non-bank, kas keliling dalam rangka penukaran, penarikan dalam

rangka kas titipan di bank umum, dan penarikan lainnya. *Net Inflow* transaksi uang kartal berarti jumlah penyetoran uang kartal (*inflow*) ke Bank Indonesia lebih besar daripada jumlah penarikan (*outflow*) uang kartal dari Bank Indonesia. Sementara itu, *net outflow* transaksi uang kartal berarti jumlah penyetoran uang kartal (*inflow*) lebih kecil daripada penarikan uang kartal (*outflow*).

Halaman ini sengaja dikosongkan

BAB 3

METODOLOGI PENELITIAN

Pada Bab 3 dibahas tahapan-tahapan penelitian yang meliputi kajian simulasi dan kajian terapan. Selain itu, informasi mengenai sumber data, variabel penelitian dan struktur data pada masing-masing metode.

3.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder yang didapatkan dari Bank Indonesia. Data yang digunakan adalah data *inflow* dan *outflow* di Wilayah II KPW BI (Jawa Barat) yang meliputi Kantor Bank Indonesia (KBI) Bandung, KBI Cirebon dan KBI Tasikmalaya. Bentuk data merupakan data bulanan yang didapatkan dari metadata statistik Bank Indonesia. Kemudian data *inflow* dan *outflow* ini akan dibagi menjadi data *in-sample* dan data *out-sample*, data *in-sample* meliputi bulan Januari tahun 2003 sampai dengan bulan Desember tahun 2013, sedangkan data *out-sample* meliputi bulan Januari tahun 2014 hingga bulan Desember tahun 2014. Peta lokasi ketiga KBI ditambihkan pada Gambar 3.1, sedangkan jarak antar lokasi di tiga kota/kabupaten tersebut disajikan dalam Tabel 3.1.



Sumber : www.maps.google.com (diolah)

Gambar 3.1 Peta Lokasi Penelitian di Tiga Lokasi di Jawa Barat

Tabel 3.1 Jarak Antar Lokasi di Tiga Lokasi di Jawa Barat

Lokasi	Jarak ke (km)		
	Kota Bandung	Kota Cirebon	Kota Tasikmalaya
Kota Bandung	0	126,3	104,6
Kota Cirebon	126,3	0	102,9
Kota Tasikmalaya	104,6	102,9	0

Sumber : www.maps.google.com (diolah)

3.2 Variabel Penelitian

Variabel dalam penelitian ini disimbolkan $Y_{i,t}$ dan $Z_{i,t}$, dengan $Y_{i,t}$ menyatakan data *inflow* dan $Z_{i,t}$ data *outflow*, $i = 1, 2, 3$ menyatakan banyaknya lokasi, dan $t = 1, 2, \dots, 144$ menyatakan periode waktu (pengamatan). Variabel penelitian yang digunakan adalah sebagai berikut:

- a. Variabel dependen, merupakan *inflow* dan *outflow*, meliputi:

Tabel 3.2 Variabel Penelitian

Data	Variabel	Keterangan
<i>Inflow</i>	$Y_{1,t}$	<i>inflow</i> di KBI Bandung pada bulan ke- t
	$Y_{2,t}$	<i>inflow</i> di KBI Cirebon pada bulan ke- t
	$Y_{3,t}$	<i>inflow</i> di KBI Tasikmalaya pada bulan ke- t
<i>Outflow</i>	$Z_{1,t}$	<i>outflow</i> di KBI Bandung pada bulan ke- t
	$Z_{2,t}$	<i>outflow</i> di KBI Cirebon pada bulan ke- t
	$Z_{3,t}$	<i>outflow</i> di KBI Tasikmalaya pada bulan ke- t

- b. Variabel independen, merupakan *dummy* variasi kalender. Pada umumnya, data *inflow* dan *outflow* mengandung pola tren, musiman, dan variasi kalender (Ahmad, Setiawan, Suhartono, & Masun, 2015; Setiawan, Suhartono, Ahmad, & Rahmawati, 2015). Dengan demikian, variabel *dummy* yang digunakan dalam penelitian ini adalah variabel *dummy* tren, musiman, dan variasi kalender. Secara rinci, variabel *dummy* yang digunakan dapat ditunjukkan pada Tabel 3.3

Tabel 3.3 Variabel *Dummy* yang Digunakan

Variabel <i>dummy</i>		Keterangan
Tren	t , dengan $t=1,2,\dots,n$	
Musiman	$S_{1,t} = \begin{cases} 1, & \text{untuk Januari pada bulan ke-}t \\ 0, & \text{lainnya} \end{cases}$	
	$S_{2,t} = \begin{cases} 1, & \text{untuk Februari pada bulan ke-}t \\ 0, & \text{lainnya} \end{cases}$	
	\vdots	
	$S_{12,t} = \begin{cases} 1, & \text{untuk Desember pada bulan ke-}t \\ 0, & \text{lainnya} \end{cases}$	
Variasi Kalender	$M_{v,t} = \begin{cases} 1, & \text{untuk Idul Fitri pada minggu ke-}v \text{ bulan ke-}t, \\ & \text{dengan } v=1,2,3,4 \\ 0, & \text{Lainnya} \end{cases}$	
	$M_{v,t-1} = \begin{cases} 1, & \text{untuk bulan sebelum Idul Fitri (bulan ke-}t) \\ & \text{pada minggu ke-}v, \text{ dengan } v=1,2,3,4 \\ 0, & \text{Lainnya} \end{cases}$	
	$M_{v,t+1} = \begin{cases} 1, & \text{untuk bulan sesudah Idul Fitri (bulan ke-}t) \\ & \text{pada minggu ke-}v, \text{ dengan } v=1,2,3,4 \\ 0, & \text{lainnya} \end{cases}$	

3.3 Struktur Data

Struktur data yang digunakan terbagi menjadi dua, yaitu untuk data *inflow* dan *outflow*.

3.3.1 Data *Inflow*

Struktur data pada data *inflow* untuk prediktor berupa variabel *dummy* yang menyatakan efek variasi kalender. Variabel *dummy* yang digunakan adalah *dummy* dengan periode mingguan pada periode satu bulan terjadinya Idul Fitri, dan periode satu bulan setelah terjadinya Idul Fitri. Pusat Riset dan Edukasi Bank Sentral (PRES) Bank Indonesia (2013) memiliki definisi sendiri dalam penentuan periode mingguan pada Tabel 3.4 sebagai berikut.

Tabel 3.4 Ketentuan Periode Mingguan

Minggu	Tanggal
1	01, 02, 03, 04, 05, 06, dan 07
2	08, 09, 10, 11, 12, 13, 14 dan 15
3	16, 17, 18, 19, 20, 21, 22 dan 23
4	Untuk bulan Februari bukan Tahun Kabisat, yaitu; 24, 25, 26, 27, dan 28 Untuk bulan Februari Tahun Kabisat, yaitu; 24, 25, 26, 27, 28 dan 29 Untuk bulan April, Juni, September dan November, yaitu; 24, 25, 26, 27, 28, 29, dan 30 Dan bulan Januari, Maret, Mei, Juli, Agustus, Oktober, dan Desember, yaitu; 24, 25, 26, 27, 28, 29, 30, dan 31

Sedangkan tanggal Hari Raya Idul Fitri dari Tahun 2003 sampai dengan 2014 dapat dilihat pada Tabel 3.5 sebagai berikut.

Tabel 3.5 Identifikasi Variabel *Dummy* selama Periode Pengamatan (*Inflow*)

Data	Tahun	Tanggal	Variabel <i>dummy</i>	Waktu (<i>t</i>)	
				$M_{v,t}$	$M_{v,t+1}$
<i>in-sample</i>	2003	26-27 November	$M_{4,t}$ = Nopember ; $M_{4,t+1}$ = Desember	11	12
	2004	14-15 November	$M_{2,t}$ = Nopember ; $M_{2,t+1}$ = Desember	23	24
	2005	03-04 November	$M_{1,t}$ = Nopember ; $M_{1,t+1}$ = Desember	35	36
	2006	23-24 Oktober	$M_{3,t}$ = Oktober ; $M_{3,t+1}$ = Nopember	46	47
	2007	12-13 Oktober	$M_{2,t}$ = Oktober ; $M_{2,t+1}$ = Nopember	58	59
	2008	01-02 Oktober	$M_{1,t}$ = Oktober ; $M_{1,t+1}$ = Nopember	70	71
	2009	21-22 September	$M_{3,t}$ = September ; $M_{3,t+1}$ = Oktober	81	82
	2010	10-11 September	$M_{2,t}$ = September ; $M_{2,t+1}$ = Oktober	93	94
	2011	30-31 Agustus	$M_{4,t}$ = Agustus ; $M_{4,t+1}$ = September	104	105
	2012	19-20 Agustus	$M_{3,t}$ = Agustus ; $M_{3,t+1}$ = September	116	117
	2013	08-09 Agustus	$M_{2,t}$ = Agustus ; $M_{2,t+1}$ = September	128	129
<i>out-sample</i>	2014	28-29 Juli	$M_{4,t}$ = Juli ; $M_{4,t+1}$ = Agustus	139	140

Sehingga struktur data yang digunakan untuk variabel *dummy* disajikan pada Tabel 3.6.

Tabel 3.6 Struktur Data *Inflow* dengan Prediktor Variabel *Dummy*

t	Bln	$Y_t^{(1)}$	$Y_t^{(2)}$	$Y_t^{(3)}$	$S_{1,t}$	\dots	$S_{12,t}$	$M_{1,t}$	\dots	$M_{4,t}$	$M_{1,t+1}$	\dots	$M_{4,t+1}$
1	01	$Y_1^{(1)}$	$Y_1^{(2)}$	$Y_1^{(3)}$	1	\dots	0	0	\dots	0	0	\dots	0
2	02	$Y_2^{(1)}$	$Y_2^{(2)}$	$Y_2^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
10	10	$Y_{10}^{(1)}$	$Y_{10}^{(2)}$	$Y_{10}^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
11	11	$Y_{11}^{(1)}$	$Y_{11}^{(2)}$	$Y_{11}^{(3)}$	0	\dots	0	1	\dots	0	0	\dots	0
12	12	$Y_{12}^{(1)}$	$Y_{12}^{(2)}$	$Y_{12}^{(3)}$	0	\dots	1	0	\dots	0	1	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
22	10	$Y_{22}^{(1)}$	$Y_{22}^{(2)}$	$Y_{22}^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
23	11	$Y_{23}^{(1)}$	$Y_{23}^{(2)}$	$Y_{23}^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
24	12	$Y_{24}^{(1)}$	$Y_{24}^{(2)}$	$Y_{24}^{(3)}$	0	\dots	1	0	\dots	0	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
139	07	$Y_{139}^{(1)}$	$Y_{139}^{(2)}$	$Y_{139}^{(3)}$	0	\dots	0	1	\dots	0	0	\dots	0
140	08	$Y_{140}^{(1)}$	$Y_{140}^{(2)}$	$Y_{140}^{(3)}$	0	\dots	0	0	\dots	0	1	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
144	12	$Y_{144}^{(1)}$	$Y_{144}^{(2)}$	$Y_{144}^{(3)}$	0	\dots	1	0	\dots	0	0	\dots	0

3.3.2 Data *Outflow*

Tanggal Hari Raya Idul Fitri tahun 2003-2014 dapat dilihat pada Tabel 3.7.

Tabel 3.7 Identifikasi Variabel *Dummy* selama Periode Pengamatan (*Outflow*)

Data	Tahun	Tanggal	Variabel <i>Dummy</i>	Waktu (t)	
				$M_{v,t}$	$M_{v,t-1}$
<i>in-sample</i>	2003	26-27 November	$M_{4,t}$ =Nopember ; $M_{4,t-1}$ = Oktober	11	10
	2004	14-15 November	$M_{2,t}$ =Nopember ; $M_{2,t-1}$ = Oktober	23	22
	2005	03-04 November	$M_{1,t}$ =Nopember ; $M_{1,t-1}$ = Oktober	35	34
	2006	23-24 Oktober	$M_{3,t}$ = Oktober ; $M_{3,t-1}$ = September	46	45
	2007	12-13 Oktober	$M_{2,t}$ = Oktober ; $M_{2,t-1}$ = September	58	57
	2008	01-02 Oktober	$M_{1,t}$ = Oktober ; $M_{1,t-1}$ = September	70	69
	2009	21-22 September	$M_{3,t}$ = September ; $M_{3,t-1}$ = Agustus	81	80
	2010	10-11 September	$M_{2,t}$ = September ; $M_{2,t-1}$ = Agustus	93	92
	2011	30-31 Agustus	$M_{4,t}$ = Agustus ; $M_{4,t-1}$ = Juli	104	103
	2012	19-20 Agustus	$M_{3,t}$ = Agustus ; $M_{3,t-1}$ = Juli	116	115
	2013	08-09 Agustus	$M_{2,t}$ = Agustus ; $M_{2,t-1}$ = Juli	128	127
<i>out-sample</i>	2014	28-29 Juli	$M_{4,t}$ = Juli ; $M_{4,t-1}$ = Juni	139	138

Sehingga struktur data yang digunakan untuk variabel *dummy* untuk efek variasi kalender disajikan pada Tabel 3.8.

Tabel 3.8 Struktur Data *Outflow* dengan Prediktor Variabel *Dummy*

t	Bulan	$Z_t^{(1)}$	$Z_t^{(2)}$	$Z_t^{(3)}$	$S_{1,t}$	\dots	$S_{12,t}$	$M_{1,t}$	\dots	$M_{4,t}$	$M_{1,t+1}$	\dots	$M_{4,t+1}$
1	01	$Z_1^{(1)}$	$Z_1^{(2)}$	$Z_1^{(3)}$	1	\dots	0	0	\dots	0	0	\dots	0
2	02	$Z_2^{(1)}$	$Z_2^{(2)}$	$Z_2^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
10	10	$Z_{10}^{(1)}$	$Z_{10}^{(2)}$	$Z_{10}^{(3)}$	0	\dots	0	0	\dots	0	1	\dots	0
11	11	$Z_{11}^{(1)}$	$Z_{11}^{(2)}$	$Z_{11}^{(3)}$	0	\dots	0	1	\dots	0	0	\dots	0
12	12	$Z_{12}^{(1)}$	$Z_{12}^{(2)}$	$Z_{12}^{(3)}$	0	\dots	1	0	\dots	0	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
21	09	$Z_{22}^{(1)}$	$Z_{22}^{(2)}$	$Z_{22}^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
22	10	$Z_{23}^{(1)}$	$Z_{23}^{(2)}$	$Z_{23}^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
23	11	$Z_{24}^{(1)}$	$Z_{24}^{(2)}$	$Z_{24}^{(3)}$	0	\dots	1	0	\dots	0	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
138	06	$Z_{139}^{(1)}$	$Z_{139}^{(2)}$	$Z_{139}^{(3)}$	0	\dots	0	0	\dots	0	1	\dots	0
139	07	$Z_{140}^{(1)}$	$Z_{140}^{(2)}$	$Z_{140}^{(3)}$	0	\dots	0	1	\dots	0	1	\dots	0
140	08	$Z_{141}^{(1)}$	$Z_{141}^{(2)}$	$Z_{141}^{(3)}$	0	\dots	0	0	\dots	0	0	\dots	0
\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots	\vdots
144	12	$Z_{144}^{(1)}$	$Z_{144}^{(2)}$	$Z_{144}^{(3)}$	0	\dots	1	0	\dots	0	0	\dots	0

3.4 Metode Penelitian

Melakukan pemodelan pada data *inflow* dan *outflow* di tiga lokasi menggunakan model VARX, *Hybrid* VARX-SVR, GSTARX dan *Hybrid* GSTARX-SVR dengan variabel eksogen. Adapun tahapan analisis yang dilakukan dalam mencapai tujuan penelitian ini adalah sebagai berikut

3.4.1 Kajian Simulasi

Kajian simulasi dilakukan untuk mengetahui performa metode VARX, GSTARX-OLS, GSTARX-GLS, *Hybrid* VARX-SVR dan *Hybrid* GSTARX-SVR dalam pemodelan data *space-time*. Untuk kemudian dilakukan perbandingan performa ketiga model berdasarkan kriteria RMSE

1. Membangkitkan *series* data (3 lokasi untuk *outflow*) masing-masing sebanyak 360 observasi dengan replikasi 10 kali yang berdistribusi multivariat normal dengan rata-rata nol dan matriks varians-kovarians Ω .
2. Menentukan besarnya nilai matriks varians-kovarians Ω dengan residual antar lokasi semua saling berkorelasi, dengan varians berbeda atau $\sigma^{(ii)} \neq \sigma^{(jj)}$. Nilai matriks varians-kovarians diberikan dengan

$$\mathbf{\Omega} = \begin{bmatrix} 0,75 & 0,20 & 0,35 \\ 0,20 & 0,4 & 0,25 \\ 0,35 & 0,25 & 0,45 \end{bmatrix}. \quad (3.1)$$

3. Mendapatkan data *time series* $N_t^{(i)}$, dengan $i = 1, 2, 3$ dan $t = 1, 2, \dots, 360$ dengan dua skenario.

a. Skenario 1, *noise* merupakan deret yang belum *white noise* berpola linier.

Komponen untuk deret *noise* pola linier sebagai berikut

$$N_t^{(i)} = \phi_1^{(i)} N_{t-1}^{(1)} + \phi_2^{(i)} N_{t-1}^{(2)} + \phi_3^{(i)} N_{t-1}^{(3)} + a_t^{(i)}, \quad (3.2)$$

dengan,

$$N_t^{(1)} = 0,35N_{t-1}^{(1)} + 0,30N_{t-1}^{(2)} + 0,30N_{t-1}^{(3)} + a_t^{(1)}.$$

$$N_t^{(2)} = 0,25N_{t-1}^{(1)} + 0,45N_{t-1}^{(2)} + 0,25N_{t-1}^{(3)} + a_t^{(2)}.$$

$$N_t^{(3)} = 0,20N_{t-1}^{(1)} + 0,20N_{t-1}^{(2)} + 0,40N_{t-1}^{(3)} + a_t^{(3)}.$$

dengan $\mathbf{a}_t \sim MN(\mathbf{0}, \mathbf{\Omega})$ dan antar lokasi saling berkorelasi.

Besarnya nilai koefisien parameter yang digunakan pada simulasi *noise* linier sesuai dengan syarat stasioner parameter model GSTAR, yaitu nilai eigen parameter kurang dari 1 (satu) atau juga dapat ditulis $|\lambda \mathbf{I} - \mathbf{\Phi}| = 0$, $|\mathbf{\Phi}| = |\lambda \mathbf{I}|$ dengan $\lambda_i < 1$. Koefisien parameter ϕ yang digunakan diberikan dengan

$$\mathbf{\Phi}_1 = \begin{bmatrix} 0,35 & 0,30 & 0,30 \\ 0,25 & 0,45 & 0,25 \\ 0,20 & 0,20 & 0,40 \end{bmatrix}. \quad (3.3)$$

b. Skenario 2, *noise* merupakan deret yang belum *white noise* dan berpola nonlinier. Komponen untuk deret *noise* pola nonlinier sebagai berikut

$$N_t^{(i)} = \phi_1^{(i)} N_{t-1}^{(1)} + \phi_2^{(i)} N_{t-1}^{(2)} + \phi_3^{(i)} N_{t-1}^{(3)} + a_t^{(i)}, \quad (3.4)$$

dengan,

$$N_t^{(1)} = 4N_{t-1}^{(1)} \times \exp\left\{-0,25\left[N_{t-1}^{(1)}\right]^2\right\} + 1,25N_{t-1}^{(2)} \times \exp\left\{-0,25\left[N_{t-1}^{(2)}\right]^2\right\} + 1,5N_{t-1}^{(3)} \times \exp\left\{-0,25\left[N_{t-1}^{(3)}\right]^2\right\} + a_t^{(1)},$$

$$\begin{aligned}
N_t^{(2)} &= 1,25N_{t-1}^{(1)} \times \exp\left\{-0,25\left[N_{t-1}^{(1)}\right]^2\right\} + 3,5N_{t-1}^{(2)} \times \exp\left\{-0,25\left[N_{t-1}^{(2)}\right]^2\right\} + \\
&\quad 1,6N_{t-1}^{(3)} \times \exp\left\{-0,25\left[N_{t-1}^{(3)}\right]^2\right\} + a_t^{(2)}, \\
N_t^{(3)} &= 1,6N_{t-1}^{(1)} \times \exp\left\{-0,25\left[N_{t-1}^{(1)}\right]^2\right\} + 1,1N_{t-1}^{(2)} \times \exp\left\{-0,25\left[N_{t-1}^{(2)}\right]^2\right\} + \\
&\quad 3N_{t-1}^{(3)} \times \exp\left\{-0,25\left[N_{t-1}^{(3)}\right]^2\right\} + a_t^{(3)}.
\end{aligned}$$

$\mathbf{a}_t \sim MN(\mathbf{0}, \Omega)$ dan antar lokasi saling berkorelasi.

4. Mendapatkan data *time series* $Y_t^{(i)}$, dengan $i = 1, 2, 3$ dan $t = 1, 2, \dots, 360$.

yang memiliki pola tren, musiman, variasi kalender.

a. Komponen tren yang digunakan merupakan komponen linier dengan persamaan sebagai berikut,

$$T_t^{(i)} = \alpha_1^{(i)} T. \quad (3.5)$$

Koefisien untuk tren yang digunakan dalam seluruh skenario adalah sama, yakni $\alpha_1^{(1)} = 0,21$; $\alpha_1^{(2)} = 0,23$; $\alpha_1^{(3)} = 0,24$.

b. Komponen musiman didapat dengan persamaan sebagai berikut,

$$S_t^{(i)} = \gamma_1^{(i)} S_{1,t} + \gamma_2^{(i)} S_{2,t} + \dots + \gamma_{12}^{(i)} S_{12,t}. \quad (3.6)$$

dengan,

$$\begin{aligned}
S_t^{(1)} &= 22S_{1,t} + 24S_{2,t} + 27S_{3,t} + 24S_{4,t} + 22S_{5,t} + 17S_{6,t} + 13S_{7,t} + \\
&\quad 10S_{8,t} + 6S_{9,t} + 10S_{10,t} + 13S_{11,t} + 17S_{12,t}.
\end{aligned}$$

$$\begin{aligned}
S_t^{(2)} &= 25S_{1,t} + 28S_{2,t} + 30S_{3,t} + 28S_{4,t} + 25S_{5,t} + 21S_{6,t} + 16S_{7,t} + \\
&\quad 13S_{8,t} + 9S_{9,t} + 13S_{10,t} + 16S_{11,t} + 21S_{12,t}.
\end{aligned}$$

$$\begin{aligned}
S_t^{(3)} &= 17S_{1,t} + 21S_{2,t} + 24S_{3,t} + 21S_{4,t} + 17S_{5,t} + 12S_{6,t} + 9S_{7,t} + \\
&\quad 6S_{8,t} + 4S_{9,t} + 6S_{10,t} + 9S_{11,t} + 12S_{12,t}.
\end{aligned}$$

c. Komponen untuk variasi kalender pada kajian simulasi ini hanya menggunakan model simulasi data *outflow*, sehingga efek variasi kalender yang digunakan adalah pada saat terjadinya Idul Fitri dan satu bulan sebelum terjadinya Idul Fitri, dengan persamaan sebagai berikut,

$$M_t^{(i)} = \delta_1^{(i)} M_{1,t} + \dots + \delta_4^{(i)} M_{4,t} + \beta_1^{(i)} M_{1,t-1} + \dots + \beta_4^{(i)} M_{4,t-1}. \quad (3.7)$$

dengan,

$$M_t^{(1)} = 32M_{1,t} + 43M_{2,t} + 47M_{3,t} + 49M_{4,t} + 50M_{1,t-1} + 46M_{2,t-1} + 39M_{3,t-1} + 34M_{4,t-1}.$$

$$M_t^{(2)} = 45M_{1,t} + 49M_{2,t} + 55M_{3,t} + 57M_{4,t} + 60M_{1,t-1} + 54M_{2,t-1} + 44M_{3,t-1} + 36M_{4,t-1}.$$

$$M_t^{(3)} = 37M_{1,t} + 40M_{2,t} + 47M_{3,t} + 51M_{4,t} + 49M_{1,t-1} + 47M_{2,t-1} + 41M_{3,t-1} + 37M_{4,t-1}.$$

5. Melakukan identifikasi pola data melalui plot *time series*. Berdasarkan plot *time series*, diasumsikan bahwa data memiliki pola tren linier, musiman, variasi kalender.
6. Melakukan pemodelan pola tren, musiman dan variasi kalender menggunakan regresi *time series* dengan tahapan sebagai berikut:
 - a. Menentukan variabel *dummy* yang digunakan. Berdasarkan identifikasi plot *time series* pada langkah 5, diasumsikan bahwa data *inflow* dan *outflow* memiliki pola tren linier, untuk musiman akan digunakan variabel *dummy* bulan dalam merekonstruksi pola musiman, dan untuk variasi kalender diasumsikan bahwa efek Idul Fitri berkaitan dengan minggu terjadinya hari raya pada bulan tersebut, satu bulan sebelumnya, dan satu bulan setelah Idul Fitri. Dengan demikian, variabel *dummy* yang digunakan adalah variabel *dummy* untuk tren, musiman bulan, dan efek variasi kalender berupa hari raya Idul Fitri seperti ditunjukkan pada Tabel 3.3
 - b. Melakukan pemodelan *time series regression* untuk pola data tren, musiman, variasi kalender secara simultan sehingga diperoleh persamaan berikut,

$$Y_t^{(i)} = T_t^{(i)} + S_t^{(i)} + M_{t-1}^{(i)} + M_t^{(i)} + N_t^{(i)} \quad (3.8)$$

$$\begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix} = \begin{pmatrix} \alpha_1^{(1)}T_t + S_t^{(1)} + M_{t-1}^{(1)} + M_t^{(1)} + N_t^{(1)} \\ \alpha_1^{(2)}T_t + S_t^{(2)} + M_{t-1}^{(2)} + M_t^{(2)} + N_t^{(2)} \\ \alpha_1^{(3)}T_t + S_t^{(3)} + M_{t-1}^{(3)} + M_t^{(3)} + N_t^{(3)} \end{pmatrix}$$

dengan

$$\begin{aligned}
S_t^{(1)} &= \gamma_1^{(1)} S_{1,t} + \gamma_2^{(1)} S_{2,t} + \gamma_3^{(1)} S_{3,t} + \gamma_4^{(1)} S_{4,t} + \cdots + \gamma_{12}^{(1)} S_{12,t}, \\
S_t^{(2)} &= \gamma_1^{(2)} S_{1,t} + \gamma_2^{(2)} S_{2,t} + \gamma_3^{(2)} S_{3,t} + \gamma_4^{(2)} S_{4,t} + \cdots + \gamma_{12}^{(2)} S_{12,t}, \\
S_t^{(3)} &= \gamma_1^{(3)} S_{1,t} + \gamma_2^{(3)} S_{2,t} + \gamma_3^{(3)} S_{3,t} + \gamma_4^{(3)} S_{4,t} + \cdots + \gamma_{12}^{(3)} S_{12,t}, \\
M_{t-1}^{(1)} &= \delta_1^{(1)} M_{1,t-1} + \delta_2^{(1)} M_{2,t-1} + \delta_3^{(1)} M_{3,t-1} + \delta_4^{(1)} M_{4,t-1}, \\
M_{t-1}^{(2)} &= \delta_1^{(2)} M_{1,t-1} + \delta_2^{(2)} M_{2,t-1} + \delta_3^{(2)} M_{3,t-1} + \delta_4^{(2)} M_{4,t-1}, \\
M_{t-1}^{(3)} &= \delta_1^{(3)} M_{1,t-1} + \delta_2^{(3)} M_{2,t-1} + \delta_3^{(3)} M_{3,t-1} + \delta_4^{(3)} M_{4,t-1}, \\
M_t^{(1)} &= \beta_1^{(1)} M_{1,t} + \beta_2^{(1)} M_{2,t} + \beta_3^{(1)} M_{3,t} + \beta_{1,4}^{(1)} M_{4,t}, \\
M_t^{(2)} &= \beta_1^{(2)} M_{1,t} + \beta_2^{(2)} M_{2,t} + \beta_3^{(2)} M_{3,t} + \beta_4^{(2)} M_{4,t}, \\
M_t^{(3)} &= \beta_1^{(3)} M_{1,t} + \beta_2^{(3)} M_{2,t} + \beta_3^{(3)} M_{3,t} + \beta_{3,4}^{(3)} M_{4,t}.
\end{aligned}$$

Sehingga dapat dimodelkan dalam bentuk

$$\begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix} = \begin{pmatrix} X^{(1)} \beta^{(1)} + N_t^{(1)} \\ X^{(2)} \beta^{(2)} + N_t^{(2)} \\ X^{(3)} \beta^{(3)} + N_t^{(3)} \end{pmatrix} \quad (3.9)$$

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{N} \quad (3.10)$$

dengan

$$\mathbf{Y} = \begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix}, \mathbf{X} = \begin{pmatrix} X^{(1)} & 0 & 0 \\ 0 & X^{(2)} & 0 \\ 0 & 0 & X^{(3)} \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \beta^{(1)} \\ \beta^{(2)} \\ \beta^{(3)} \end{pmatrix}, \mathbf{N} = \begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix}$$

$$\begin{aligned}
X^{(1)} &= (T \quad S_{1,t} \quad \cdots \quad S_{12,t} \quad M_{1,t-1} \quad \cdots \quad M_{4,t-1} \quad M_{1,t} \quad \cdots \quad M_{4,t}), \\
X^{(2)} &= (T \quad S_{1,t} \quad \cdots \quad S_{12,t} \quad M_{1,t-1} \quad \cdots \quad M_{4,t-1} \quad M_{1,t} \quad \cdots \quad M_{4,t}), \\
X^{(3)} &= (T \quad S_{1,t} \quad \cdots \quad S_{12,t} \quad M_{1,t-1} \quad \cdots \quad M_{4,t-1} \quad M_{1,t} \quad \cdots \quad M_{4,t}),
\end{aligned}$$

$$\begin{aligned}
\beta^{(1)} &= (\alpha_1^{(1)} \quad \gamma_1^{(1)} \quad \cdots \quad \gamma_{12}^{(1)} \quad \delta_1^{(1)} \quad \cdots \quad \delta_4^{(1)} \quad \beta_1^{(1)} \quad \cdots \quad \beta_4^{(1)}), \\
\beta^{(2)} &= (\alpha_1^{(2)} \quad \gamma_1^{(2)} \quad \cdots \quad \gamma_{12}^{(2)} \quad \delta_1^{(2)} \quad \cdots \quad \delta_4^{(2)} \quad \beta_1^{(2)} \quad \cdots \quad \beta_4^{(2)}), \\
\beta^{(3)} &= (\alpha_1^{(3)} \quad \gamma_1^{(3)} \quad \cdots \quad \gamma_{12}^{(3)} \quad \delta_1^{(3)} \quad \cdots \quad \delta_4^{(3)} \quad \beta_1^{(3)} \quad \cdots \quad \beta_4^{(3)}).
\end{aligned}$$

Maka didapatkan $\hat{\alpha}_1^{(1)}, \hat{\alpha}_1^{(2)}, \hat{\alpha}_1^{(3)}, \hat{\gamma}_1^{(1)}, \dots, \hat{\gamma}_{12}^{(1)}, \hat{\gamma}_1^{(2)}, \dots, \hat{\gamma}_{12}^{(2)}, \hat{\gamma}_1^{(3)}, \dots, \hat{\gamma}_{12}^{(3)},$
 $\hat{\delta}_1^{(1)}, \dots, \hat{\delta}_4^{(1)}, \hat{\delta}_1^{(2)}, \dots, \hat{\delta}_4^{(2)}, \hat{\delta}_1^{(3)}, \dots, \hat{\delta}_4^{(3)}, \hat{\beta}_1^{(1)}, \dots, \hat{\beta}_4^{(1)}, \hat{\beta}_1^{(2)}, \dots, \hat{\beta}_4^{(2)}, \hat{\beta}_1^{(3)}, \dots, \hat{\beta}_4^{(3)},$

dengan masing-masing *standart error* (SE) serta diperoleh data series

$N_t^{(i)}$. Metode estimasi parameter yang digunakan adalah OLS dan GLS.

7. Memodelkan residual yang diperoleh dari regresi *time series* dengan menggunakan VAR dan GSTAR dengan tahapan identifikasi, estimasi, dan cek diagnosa sehingga diperoleh orde untuk model VAR(1) dan GSTAR(1₁) dengan bobot seragam pada skenario residual linier dan VAR(2) dan GSTAR(2₁) pada skenario residual nonlinier. Maka diperoleh persamaan berikut untuk VAR(1),

$$\begin{aligned} N_t^{(1)} &= \phi_{11}N_{t-1}^{(1)} + \phi_{12}N_{t-1}^{(2)} + \phi_{13}N_{t-1}^{(3)} + a_t^{(1)} \\ N_t^{(2)} &= \phi_{21}N_{t-1}^{(1)} + \phi_{22}N_{t-1}^{(2)} + \phi_{23}N_{t-1}^{(3)} + a_t^{(2)} \\ N_t^{(3)} &= \phi_{31}N_{t-1}^{(1)} + \phi_{32}N_{t-1}^{(2)} + \phi_{33}N_{t-1}^{(3)} + a_t^{(3)}. \end{aligned} \quad (3.11)$$

untuk VAR(2),

$$\begin{aligned} N_t^{(1)} &= \phi_{11}^{(1)}N_{t-1}^{(1)} + \phi_{12}^{(1)}N_{t-1}^{(2)} + \phi_{13}^{(1)}N_{t-1}^{(3)} + \phi_{11}^{(2)}N_{t-2}^{(1)} + \phi_{12}^{(2)}N_{t-2}^{(2)} + \phi_{13}^{(2)}N_{t-2}^{(3)} + a_t^{(1)} \\ N_t^{(2)} &= \phi_{21}^{(1)}N_{t-1}^{(1)} + \phi_{22}^{(1)}N_{t-1}^{(2)} + \phi_{23}^{(1)}N_{t-1}^{(3)} + \phi_{21}^{(2)}N_{t-2}^{(1)} + \phi_{22}^{(2)}N_{t-2}^{(2)} + \phi_{23}^{(2)}N_{t-2}^{(3)} + a_t^{(2)} \\ N_t^{(3)} &= \phi_{31}^{(1)}N_{t-1}^{(1)} + \phi_{32}^{(1)}N_{t-1}^{(2)} + \phi_{33}^{(1)}N_{t-1}^{(3)} + \phi_{31}^{(2)}N_{t-2}^{(1)} + \phi_{32}^{(2)}N_{t-2}^{(2)} + \phi_{33}^{(2)}N_{t-2}^{(3)} + a_t^{(3)}. \end{aligned} \quad (3.12)$$

Sedangkan untuk GSTAR(1₁)

$$\begin{aligned} N_t^{(1)} &= \phi_{10}N_{t-1}^{(1)} + \phi_{11}w_{12}N_{t-1}^{(2)} + \phi_{11}w_{13}N_{t-1}^{(3)} + a_t^{(1)} \\ N_t^{(2)} &= \phi_{20}N_{t-1}^{(2)} + \phi_{21}w_{21}N_{t-1}^{(1)} + \phi_{21}w_{23}N_{t-1}^{(3)} + a_t^{(2)} \\ N_t^{(3)} &= \phi_{30}N_{t-1}^{(3)} + \phi_{31}w_{31}N_{t-1}^{(1)} + \phi_{31}w_{32}N_{t-1}^{(2)} + a_t^{(3)}. \end{aligned} \quad (3.13)$$

untuk GSTAR(2₁)

$$\begin{aligned} N_t^{(1)} &= \phi_{10}^{(1)}N_{t-1}^{(1)} + \phi_{11}^{(1)}w_{12}^{(1)}N_{t-1}^{(2)} + \phi_{11}^{(1)}w_{13}^{(1)}N_{t-1}^{(3)} + \phi_{10}^{(2)}N_{t-2}^{(1)} + \phi_{11}^{(2)}w_{12}^{(2)}N_{t-2}^{(2)} + \\ &\quad \phi_{11}^{(2)}w_{13}^{(2)}N_{t-2}^{(3)} + a_t^{(1)} \\ N_t^{(2)} &= \phi_{20}^{(1)}N_{t-1}^{(2)} + \phi_{21}^{(1)}w_{21}^{(1)}N_{t-1}^{(1)} + \phi_{21}^{(1)}w_{23}^{(1)}N_{t-1}^{(3)} + \phi_{20}^{(2)}N_{t-2}^{(2)} + \phi_{21}^{(2)}w_{21}^{(2)}N_{t-2}^{(1)} + \\ &\quad \phi_{21}^{(2)}w_{23}^{(2)}N_{t-2}^{(3)} + a_t^{(2)} \\ N_t^{(3)} &= \phi_{30}^{(1)}N_{t-1}^{(3)} + \phi_{31}^{(1)}w_{31}^{(1)}N_{t-1}^{(1)} + \phi_{31}^{(1)}w_{32}^{(1)}N_{t-1}^{(2)} + \phi_{30}^{(2)}N_{t-2}^{(3)} + \phi_{31}^{(2)}w_{31}^{(2)}N_{t-2}^{(1)} + \\ &\quad \phi_{31}^{(2)}w_{32}^{(2)}N_{t-2}^{(2)} + a_t^{(3)}. \end{aligned} \quad (3.14)$$

Sehingga dapat dimodelkan dalam bentuk

$$\begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix} = \begin{pmatrix} X^{(1)*} \beta^{(1)*} + a_t^{(1)} \\ X^{(2)*} \beta^{(2)*} + a_t^{(2)} \\ X^{(3)*} \beta^{(3)*} + a_t^{(3)} \end{pmatrix} \quad (3.15)$$

$$\mathbf{N} = \mathbf{X}^* \boldsymbol{\beta}^* + \mathbf{a} \quad (3.16)$$

dengan

$$\mathbf{N} = \begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix}, \mathbf{X}^* = \begin{pmatrix} X^{(1)*} & 0 & 0 \\ 0 & X^{(2)*} & 0 \\ 0 & 0 & X^{(3)*} \end{pmatrix}, \boldsymbol{\beta}^* = \begin{pmatrix} \beta^{(1)*} \\ \beta^{(2)*} \\ \beta^{(3)*} \end{pmatrix}, \mathbf{a} = \begin{pmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{pmatrix}$$

untuk VAR(1)

$$X^{(1)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(2)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(3)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$\beta^{(1)*} = (\phi_{11} \quad \phi_{12} \quad \phi_{13})',$$

$$\beta^{(2)*} = (\phi_{21} \quad \phi_{22} \quad \phi_{23})',$$

$$\beta^{(3)*} = (\phi_{31} \quad \phi_{32} \quad \phi_{33})'$$

untuk VAR(2)

$$X^{(1)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} & N_{t-2}^{(1)} & N_{t-2}^{(2)} & N_{t-2}^{(3)} \end{pmatrix},$$

$$X^{(2)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} & N_{t-2}^{(1)} & N_{t-2}^{(2)} & N_{t-2}^{(3)} \end{pmatrix},$$

$$X^{(3)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} & N_{t-2}^{(1)} & N_{t-2}^{(2)} & N_{t-2}^{(3)} \end{pmatrix},$$

$$\beta^{(1)*} = (\phi_{11}^1 \quad \phi_{12}^1 \quad \phi_{13}^1 \quad \phi_{11}^2 \quad \phi_{12}^2 \quad \phi_{13}^2)',$$

$$\beta^{(2)*} = (\phi_{21}^1 \quad \phi_{22}^1 \quad \phi_{23}^1 \quad \phi_{21}^2 \quad \phi_{22}^2 \quad \phi_{23}^2)',$$

$$\beta^{(3)*} = (\phi_{31}^1 \quad \phi_{32}^1 \quad \phi_{33}^1 \quad \phi_{31}^2 \quad \phi_{32}^2 \quad \phi_{33}^2)'$$

untuk GSTAR(1₁)

$$X^{(1)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(2)*} = \begin{pmatrix} N_{t-1}^{(2)} & N_{t-1}^{(1)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(3)*} = \begin{pmatrix} N_{t-1}^{(3)} & N_{t-1}^{(1)} & N_{t-1}^{(2)} \end{pmatrix},$$

$$\beta^{(1)*} = (\phi_{10} \quad \phi_{11} w_{12} \quad \phi_{11} w_{13})',$$

$$\beta^{(2)*} = (\phi_{20} \quad \phi_{21} w_{21} \quad \phi_{21} w_{23})',$$

$$\beta^{(3)*} = (\phi_{30} \quad \phi_{31} w_{31} \quad \phi_{11} w_{32})'.$$

dan untuk GSTAR(2₁)

$$X^{(1)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} & N_{t-2}^{(1)} & N_{t-2}^{(2)} & N_{t-2}^{(3)} \end{pmatrix},$$

$$X^{(2)*} = \begin{pmatrix} N_{t-1}^{(2)} & N_{t-1}^{(1)} & N_{t-1}^{(3)} & N_{t-2}^{(2)} & N_{t-2}^{(1)} & N_{t-2}^{(3)} \end{pmatrix},$$

$$X^{(3)*} = \begin{pmatrix} N_{t-1}^{(3)} & N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-2}^{(3)} & N_{t-2}^{(1)} & N_{t-2}^{(2)} \end{pmatrix},$$

$$\beta^{(1)*} = \begin{pmatrix} \phi_{10}^1 & \phi_{11}^1 w_{12}^1 & \phi_{11}^1 w_{13}^1 & \phi_{10}^2 & \phi_{11}^2 w_{12}^2 & \phi_{11}^2 w_{13}^2 \end{pmatrix}',$$

$$\beta^{(2)*} = \begin{pmatrix} \phi_{20}^1 & \phi_{21}^1 w_{21}^1 & \phi_{21}^1 w_{23}^1 & \phi_{20}^2 & \phi_{21}^2 w_{21}^2 & \phi_{21}^2 w_{23}^2 \end{pmatrix}',$$

$$\beta^{(3)*} = \begin{pmatrix} \phi_{30}^1 & \phi_{31}^1 w_{31}^1 & \phi_{11}^1 w_{32}^1 & \phi_{30}^2 & \phi_{31}^2 w_{31}^2 & \phi_{31}^2 w_{32}^2 \end{pmatrix}'.$$

Maka didapatkan $\hat{\phi}_{11}, \hat{\phi}_{12}, \hat{\phi}_{13}, \hat{\phi}_{21}, \hat{\phi}_{22}, \hat{\phi}_{23}, \hat{\phi}_{31}, \hat{\phi}_{32}, \hat{\phi}_{33}$ untuk VAR(1) dan $\hat{\phi}_{11}^1, \hat{\phi}_{12}^1, \hat{\phi}_{13}^1, \hat{\phi}_{21}^1, \hat{\phi}_{22}^1, \hat{\phi}_{23}^1, \hat{\phi}_{31}^1, \hat{\phi}_{32}^1, \hat{\phi}_{33}^1, \hat{\phi}_{11}^2, \hat{\phi}_{12}^2, \hat{\phi}_{13}^2, \hat{\phi}_{21}^2, \hat{\phi}_{22}^2, \hat{\phi}_{23}^2, \hat{\phi}_{31}^2, \hat{\phi}_{32}^2, \hat{\phi}_{33}^2$ untuk VAR(2) dengan masing-masing *standart error* (SE). Serta $\hat{\phi}_{10}, \hat{\phi}_{20}, \hat{\phi}_{30}, \hat{\phi}_{11}, \hat{\phi}_{21}, \hat{\phi}_{31}$ untuk GSTAR(1₁) dan $\hat{\phi}_{10}^1, \hat{\phi}_{20}^1, \hat{\phi}_{30}^1, \hat{\phi}_{11}^1, \hat{\phi}_{21}^1, \hat{\phi}_{31}^1, \hat{\phi}_{10}^2, \hat{\phi}_{20}^2, \hat{\phi}_{30}^2, \hat{\phi}_{11}^2, \hat{\phi}_{21}^2, \hat{\phi}_{31}^2$ untuk GSTAR(2₁) dengan masing-masing *standart error* (SE). Kemudian diperoleh data series $a_t^{(i)}$.

Estimasi parameter GSTAR menggunakan metode OLS dan GLS

8. Memodelkan residual yang diperoleh dari regresi *time series* pada langkah 6 dengan menggunakan SVR sehingga diperoleh model *Hybrid VARX-SVR* dan *Hybrid GSTARX-SVR*. Tahapan yang dilakukan adalah sebagai berikut:
 - a. Menentukan variabel *input* yang akan digunakan dalam SVR. Penentuan variabel *input* yang digunakan sama dengan *input* pada model VARX dan GSTARX.

$$\begin{aligned} N_t^{(1)} &= \sum_{t=1}^n (\beta_t - \beta_t^*) K(x_t, \mathbf{x}) + b^{(1)}, \\ N_t^{(2)} &= \sum_{t=1}^n (\beta_t - \beta_t^*) K(x_t, \mathbf{x}) + b^{(2)}, \\ N_t^{(3)} &= \sum_{t=1}^n (\beta_t - \beta_t^*) K(x_t, \mathbf{x}) + b^{(3)}, \end{aligned} \quad (3.17)$$

Dengan fungsi Kernel *Radial Basis Function* seperti pada persamaan 2.84 subbab 2.6.1

- b. Menentukan fungsi kernel, nilai-nilai parameter kernel dan parameter *cost* dari parameter epsilon untuk optimasi *hyperplane* pada data *training*. Nabila (207) menentukan epsilon pada range 0,00005-0,00009

- dengan selisih 10^{-5} . *Cost* pada range 350-355 dengan selisih 0,1. Serta σ pada range 0,05-0,1 dengan selisih 10^{-7} .
- c. Memilih nilai parameter terbaik menggunakan metode *grid-search* pada tiap *hyperplane* dengan cara sebagai berikut:
 - i. Optimasi parameter α dan β
 - ii. Menggunakan *hyperplane-hyperplane* tersebut untuk tiap model regresi
 - iii. Hitung *error* tiap model regresi
 - iv. Hitung rata-rata *error* hasil regresi untuk setiap *hyperplane*.
 - v. Menentukan *hyperplane* terbaik.
 - d. Menggunakan *hyperplane* dengan parameter terbaik yang diperoleh pada regresi data *testing* untuk masing-masing lokasi
 - e. Estimasi nilai RMSE.
9. Melakukan peramalan titik untuk data *testing* menggunakan metode VARX, GSTARX, *Hybrid* VARX-SVR dan *Hybrid* GSTARX-SVR, kemudian menghitung tingkat kesalahan peramalan untuk data *testing*, untuk kemudian dapat disimpulkan metode terbaik.

3.4.2 Kajian Terapan

Melakukan pemodelan pada data *inflow* dan *outflow* di tiga lokasi menggunakan model VARX, *Hybrid* VARX-SVR, GSTARX dan *Hybrid* GSTARX-SVR. Tahapan yang dilakukan adalah sebagai berikut:

1. Melakukan analisis statistika deskriptif pada KBI Bandung, KBI Cirebon dan KBI Tasikmalaya untuk mengetahui karakteristik data *inflow* dan *outflow*, dengan langkah sebagai berikut:
 - a. Melakukan perhitungan statistika deskriptif untuk data *inflow* dan *outflow*, meliputi *mean*, *median*, standar deviasi, *skewness*, dan kurtosis.
 - b. Melakukan identifikasi pola data *inflow* dan *outflow* melalui plot *time series*. Berdasarkan plot *time series*, diasumsikan bahwa data memiliki pola tren linier, musiman, variasi kalender, dan residual yang tidak *random*.

2. Menentukan data *in-sample* dan data *out-sample*, dimana data *in-sample* adalah data *inflow* dan *outflow* pada bulan Januari tahun 2003 sampai bulan Desember tahun 2013, sedangkan untuk data *out-sample* merupakan data *inflow* dan *outflow* pada bulan Januari tahun 2014 hingga bulan Desember tahun 2014.
3. Melakukan pemodelan pola tren, musiman dan variasi kalender untuk data *inflow* dan *outflow* menggunakan regresi *time series* dengan tahapan sebagai berikut:
 - a. Menentukan variabel *dummy* yang digunakan. Berdasarkan identifikasi plot *time series* pada langkah 2b, diasumsikan bahwa data memiliki pola tren, musiman, variasi kalender, dan residual yang tidak *random*. Untuk tren, diasumsikan bahwa data *inflow* dan *outflow* memiliki pola tren linier, untuk musiman akan digunakan variabel *dummy* bulan dalam merekonstruksi pola musiman, dan untuk variasi kalender diasumsikan bahwa efek Idul Fitri berkaitan dengan minggu terjadinya hari raya pada bulan tersebut, satu bulan sebelumnya, dan satu bulan setelah Idul Fitri. Dengan demikian, variabel *dummy* yang digunakan adalah variabel *dummy* untuk tren, musiman bulan, dan efek variasi kalender berupa hari raya Idul Fitri.
 - b. Melakukan pemodelan *time series regression* untuk pola data tren, musiman, kalender variasi secara simultan sehingga diperoleh persamaan berikut untuk data *inflow*,

$$\begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix} = \begin{pmatrix} T_t^{(1)} + S_t^{(1)} + M_{t+1,t}^{(1)} + M_{t,t}^{(1)} + N_t^{(1)} \\ T_t^{(2)} + S_t^{(2)} + M_{t+1,t}^{(2)} + M_{t,t}^{(2)} + N_t^{(2)} \\ T_t^{(3)} + S_t^{(3)} + M_{t+1,t}^{(3)} + M_{t,t}^{(3)} + N_t^{(3)} \end{pmatrix} \quad (3.18)$$

Dengan

$$\begin{aligned} T_t^{(1)} &= \alpha_1^{(1)} T_{1,t} + \alpha_2^{(1)} D_{1,t} + \alpha_3^{(1)} D_{2,t} + \alpha_4^{(1)} TD_{1,t} + \alpha_5^{(1)} TD_{2,t}, \\ T_t^{(2)} &= \alpha_1^{(2)} T_{1,t} + \alpha_2^{(2)} D_{1,t} + \alpha_3^{(2)} D_{2,t} + \alpha_4^{(2)} TD_{1,t} + \alpha_5^{(2)} TD_{2,t}, \\ T_t^{(3)} &= \alpha_1^{(3)} T_{1,t} + \alpha_2^{(3)} D_{1,t} + \alpha_3^{(3)} D_{2,t} + \alpha_4^{(3)} TD_{1,t} + \alpha_5^{(3)} TD_{2,t}, \end{aligned}$$

$$\begin{aligned}
S_t^{(1)} &= \gamma_1^{(1)} S_{1,t} + \gamma_2^{(1)} S_{2,t} + \gamma_3^{(1)} S_{3,t} + \gamma_4^{(1)} S_{4,t} + \cdots + \gamma_{12}^{(1)} S_{12,t}, \\
S_t^{(2)} &= \gamma_1^{(2)} S_{1,t} + \gamma_2^{(2)} S_{2,t} + \gamma_3^{(2)} S_{3,t} + \gamma_4^{(2)} S_{4,t} + \cdots + \gamma_{12}^{(2)} S_{12,t}, \\
S_t^{(3)} &= \gamma_1^{(3)} S_{1,t} + \gamma_2^{(3)} S_{2,t} + \gamma_3^{(3)} S_{3,t} + \gamma_4^{(3)} S_{4,t} + \cdots + \gamma_{12}^{(3)} S_{12,t}, \\
M_{t+1,t}^{(1)} &= \delta_1^{(1)} M_{1,t+1} + \delta_2^{(1)} M_{2,t+1} + \delta_3^{(1)} M_{3,t+1} + \delta_4^{(1)} M_{4,t+1}, \\
M_{t+1,t}^{(2)} &= \delta_1^{(2)} M_{1,t+1} + \delta_2^{(2)} M_{2,t+1} + \delta_3^{(2)} M_{3,t+1} + \delta_4^{(2)} M_{4,t+1}, \\
M_{t+1,t}^{(3)} &= \delta_1^{(3)} M_{1,t+1} + \delta_2^{(3)} M_{2,t+1} + \delta_3^{(3)} M_{3,t+1} + \delta_4^{(3)} M_{4,t+1}, \\
M_{t,t}^{(1)} &= \beta_1^{(1)} M_{1,t} + \beta_2^{(1)} M_{2,t} + \beta_3^{(1)} M_{3,t} + \beta_{1,4}^{(1)} M_{4,t}, \\
M_{t,t}^{(2)} &= \beta_1^{(2)} M_{1,t} + \beta_2^{(2)} M_{2,t} + \beta_3^{(2)} M_{3,t} + \beta_4^{(2)} M_{4,t}, \\
M_{t,t}^{(3)} &= \beta_1^{(3)} M_{1,t} + \beta_2^{(3)} M_{2,t} + \beta_3^{(3)} M_{3,t} + \beta_{3,4}^{(3)} M_{4,t}.
\end{aligned}$$

Sehingga dapat dimodelkan dalam bentuk

$$\begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix} = \begin{pmatrix} X^{(1)} \beta^{(1)} + N_t^{(1)} \\ X^{(2)} \beta^{(2)} + N_t^{(2)} \\ X^{(3)} \beta^{(3)} + N_t^{(3)} \end{pmatrix} \quad (3.19)$$

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{N} \quad (3.20)$$

dengan

$$\begin{aligned}
\mathbf{Y} &= \begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix}, \quad \mathbf{X} = \begin{pmatrix} X^{(1)} & 0 & 0 \\ 0 & X^{(2)} & 0 \\ 0 & 0 & X^{(3)} \end{pmatrix}, \quad \boldsymbol{\beta} = \begin{pmatrix} \beta^{(1)} \\ \beta^{(2)} \\ \beta^{(3)} \end{pmatrix}, \quad \mathbf{N} = \begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix} \\
X^{(1)} &= (T \quad D_{1,t} \quad D_{2,t} \quad TD_{1,t} \quad TD_{2,t} \quad S_{1,t} \quad \cdots \quad S_{12,t} \quad M_{1,t+1} \quad \cdots \quad M_{4,t+1} \quad M_{1,t} \quad \cdots \quad M_{4,t}), \\
X^{(2)} &= (T \quad D_{1,t} \quad D_{2,t} \quad TD_{1,t} \quad TD_{2,t} \quad S_{1,t} \quad \cdots \quad S_{12,t} \quad M_{1,t+1} \quad \cdots \quad M_{4,t+1} \quad M_{1,t} \quad \cdots \quad M_{4,t}), \\
X^{(3)} &= (T \quad D_{1,t} \quad D_{2,t} \quad TD_{1,t} \quad TD_{2,t} \quad S_{1,t} \quad \cdots \quad S_{12,t} \quad M_{1,t+1} \quad \cdots \quad M_{4,t+1} \quad M_{1,t} \quad \cdots \quad M_{4,t}), \\
\beta^{(1)} &= (\alpha_1^{(1)} \quad \cdots \quad \alpha_5^{(1)} \quad \gamma_1^{(1)} \quad \cdots \quad \gamma_{12}^{(1)} \quad \delta_1^{(1)} \quad \cdots \quad \delta_4^{(1)} \quad \beta_1^{(1)} \quad \cdots \quad \beta_4^{(1)}), \\
\beta^{(2)} &= (\alpha_1^{(2)} \quad \cdots \quad \alpha_5^{(1)} \quad \gamma_1^{(2)} \quad \cdots \quad \gamma_{12}^{(2)} \quad \delta_1^{(2)} \quad \cdots \quad \delta_4^{(2)} \quad \beta_1^{(2)} \quad \cdots \quad \beta_4^{(2)}), \\
\beta^{(3)} &= (\alpha_1^{(3)} \quad \cdots \quad \alpha_5^{(1)} \quad \gamma_1^{(3)} \quad \cdots \quad \gamma_{12}^{(3)} \quad \delta_1^{(3)} \quad \cdots \quad \delta_4^{(3)} \quad \beta_1^{(3)} \quad \cdots \quad \beta_4^{(3)}).
\end{aligned}$$

Maka didapatkan

$$\begin{aligned} &\hat{\alpha}_1^{(1)}, \dots, \hat{\alpha}_5^{(1)}, \hat{\alpha}_1^{(2)}, \dots, \hat{\alpha}_5^{(2)}, \hat{\alpha}_1^{(3)}, \dots, \hat{\alpha}_5^{(3)} \quad \hat{\gamma}_1^{(1)}, \dots, \hat{\gamma}_{12}^{(1)}, \quad \hat{\gamma}_1^{(2)}, \dots, \hat{\gamma}_{12}^{(2)}, \\ &\hat{\gamma}_1^{(3)}, \dots, \hat{\gamma}_{12}^{(3)}, \quad \hat{\delta}_1^{(1)}, \dots, \hat{\delta}_4^{(1)}, \hat{\delta}_1^{(2)}, \dots, \hat{\delta}_4^{(2)}, \hat{\delta}_1^{(3)}, \dots, \hat{\delta}_4^{(3)}, \quad \hat{\beta}_1^{(1)}, \dots, \hat{\beta}_4^{(1)}, \\ &\hat{\beta}_1^{(2)}, \dots, \hat{\beta}_4^{(2)}, \hat{\beta}_1^{(3)}, \dots, \hat{\beta}_4^{(3)} \end{aligned}$$

dengan masing-masing *standart error* (SE) serta diperoleh data series $N_t^{(i)}$. Metode estimasi parameter yang digunakan adalah OLS dan GLS.

Sedangkan untuk data *outflow* diperoleh

$$\begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix} = \begin{pmatrix} T_t^{(1)} + S_t^{(1)} + M_{t-1,t}^{(1)} + M_{t,t}^{(1)} + N_t^{(1)} \\ T_t^{(2)} + S_t^{(2)} + M_{t-1,t}^{(2)} + M_{t,t}^{(2)} + N_t^{(2)} \\ T_t^{(3)} + S_t^{(3)} + M_{t-1,t}^{(3)} + M_{t,t}^{(3)} + N_t^{(3)} \end{pmatrix} \quad (3.21)$$

dengan

$$\begin{aligned} T_t^{(1)} &= \alpha_1^{(1)} T_{1,t} + \alpha_2^{(1)} D_{1,t} + \alpha_3^{(1)} D_{2,t} + \alpha_4^{(1)} TD_{1,t} + \alpha_5^{(1)} TD_{2,t}, \\ T_t^{(2)} &= \alpha_1^{(2)} T_{1,t} + \alpha_2^{(2)} D_{1,t} + \alpha_3^{(2)} D_{2,t} + \alpha_4^{(2)} TD_{1,t} + \alpha_5^{(2)} TD_{2,t}, \\ T_t^{(3)} &= \alpha_1^{(3)} T_{1,t} + \alpha_2^{(3)} D_{1,t} + \alpha_3^{(3)} D_{2,t} + \alpha_4^{(3)} TD_{1,t} + \alpha_5^{(3)} TD_{2,t}, \\ S_t^{(1)} &= \gamma_1^{(1)} S_{1,t} + \gamma_2^{(1)} S_{2,t} + \gamma_3^{(1)} S_{3,t} + \gamma_4^{(1)} S_{4,t} + \dots + \gamma_{12}^{(1)} S_{12,t}, \\ S_t^{(2)} &= \gamma_1^{(2)} S_{1,t} + \gamma_2^{(2)} S_{2,t} + \gamma_3^{(2)} S_{3,t} + \gamma_4^{(2)} S_{4,t} + \dots + \gamma_{12}^{(2)} S_{12,t}, \\ S_t^{(3)} &= \gamma_1^{(3)} S_{1,t} + \gamma_2^{(3)} S_{2,t} + \gamma_3^{(3)} S_{3,t} + \gamma_4^{(3)} S_{4,t} + \dots + \gamma_{12}^{(3)} S_{12,t}, \\ M_{t-1,t}^{(1)} &= \delta_1^{(1)} M_{1,t-1} + \delta_2^{(1)} M_{2,t-1} + \delta_3^{(1)} M_{3,t-1} + \delta_4^{(1)} M_{4,t-1}, \\ M_{t-1,t}^{(2)} &= \delta_1^{(2)} M_{1,t-1} + \delta_2^{(2)} M_{2,t-1} + \delta_3^{(2)} M_{3,t-1} + \delta_4^{(2)} M_{4,t-1}, \\ M_{t-1,t}^{(3)} &= \delta_1^{(3)} M_{1,t-1} + \delta_2^{(3)} M_{2,t-1} + \delta_3^{(3)} M_{3,t-1} + \delta_4^{(3)} M_{4,t-1}, \\ M_{t,t}^{(1)} &= \beta_1^{(1)} M_{1,t} + \beta_2^{(1)} M_{2,t} + \beta_3^{(1)} M_{3,t} + \beta_{1,4}^{(1)} M_{4,t}, \\ M_{t,t}^{(2)} &= \beta_1^{(2)} M_{1,t} + \beta_2^{(2)} M_{2,t} + \beta_3^{(2)} M_{3,t} + \beta_4^{(2)} M_{4,t}, \\ M_{t,t}^{(3)} &= \beta_1^{(3)} M_{1,t} + \beta_2^{(3)} M_{2,t} + \beta_3^{(3)} M_{3,t} + \beta_{3,4}^{(3)} M_{4,t}. \end{aligned}$$

Sehingga dapat dimodelkan dalam bentuk

$$\begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix} = \begin{pmatrix} X^{(1)} \beta^{(1)} + N_t^{(1)} \\ X^{(2)} \beta^{(2)} + N_t^{(2)} \\ X^{(3)} \beta^{(3)} + N_t^{(3)} \end{pmatrix} \quad (3.22)$$

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{N} \quad (3.23)$$

dengan

$$\mathbf{Y} = \begin{pmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{pmatrix}, \mathbf{X} = \begin{pmatrix} X^{(1)} & 0 & 0 \\ 0 & X^{(2)} & 0 \\ 0 & 0 & X^{(3)} \end{pmatrix}, \boldsymbol{\beta} = \begin{pmatrix} \beta^{(1)} \\ \beta^{(2)} \\ \beta^{(3)} \end{pmatrix}, \mathbf{N} = \begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix}$$

$$X^{(1)} = (T \ D_{1,t} \ D_{2,t} \ TD_{1,t} \ TD_{2,t} \ S_{1,t} \ \dots \ S_{12,t} \ M_{1,t-1} \ \dots \ M_{4,t-1} \ M_{1,t} \ \dots \ M_{4,t}),$$

$$X^{(2)} = (T \ D_{1,t} \ D_{2,t} \ TD_{1,t} \ TD_{2,t} \ S_{1,t} \ \dots \ S_{12,t} \ M_{1,t-1} \ \dots \ M_{4,t-1} \ M_{1,t} \ \dots \ M_{4,t}),$$

$$X^{(3)} = (T \ D_{1,t} \ D_{2,t} \ TD_{1,t} \ TD_{2,t} \ S_{1,t} \ \dots \ S_{12,t} \ M_{1,t-1} \ \dots \ M_{4,t-1} \ M_{1,t} \ \dots \ M_{4,t}),$$

$$\beta^{(1)} = (\alpha_1^{(1)} \ \dots \ \alpha_5^{(1)} \ \gamma_1^{(1)} \ \dots \ \gamma_{12}^{(1)} \ \delta_1^{(1)} \ \dots \ \delta_4^{(1)} \ \beta_1^{(1)} \ \dots \ \beta_4^{(1)}),$$

$$\beta^{(2)} = (\alpha_0^{(2)} \ \dots \ \alpha_5^{(1)} \ \gamma_1^{(2)} \ \dots \ \gamma_{12}^{(2)} \ \delta_1^{(2)} \ \dots \ \delta_4^{(2)} \ \beta_1^{(2)} \ \dots \ \beta_4^{(2)}),$$

$$\beta^{(3)} = (\alpha_0^{(3)} \ \dots \ \alpha_5^{(1)} \ \gamma_1^{(3)} \ \dots \ \gamma_{12}^{(3)} \ \delta_1^{(3)} \ \dots \ \delta_4^{(3)} \ \beta_1^{(3)} \ \dots \ \beta_4^{(3)}).$$

Maka didapatkan

$$\hat{\alpha}_1^{(1)}, \dots, \hat{\alpha}_5^{(1)}, \hat{\alpha}_1^{(2)}, \dots, \hat{\alpha}_5^{(2)}, \hat{\alpha}_1^{(3)}, \dots, \hat{\alpha}_5^{(3)} \quad \hat{\gamma}_1^{(1)}, \dots, \hat{\gamma}_{12}^{(1)}, \quad \hat{\gamma}_1^{(2)}, \dots, \hat{\gamma}_{12}^{(2)},$$

$$\hat{\gamma}_1^{(3)}, \dots, \hat{\gamma}_{12}^{(3)}, \quad \hat{\delta}_1^{(1)}, \dots, \hat{\delta}_4^{(1)}, \hat{\delta}_1^{(2)}, \dots, \hat{\delta}_4^{(2)}, \hat{\delta}_1^{(3)}, \dots, \hat{\delta}_4^{(3)},$$

$$\hat{\beta}_1^{(1)}, \dots, \hat{\beta}_4^{(1)}, \hat{\beta}_1^{(2)}, \dots, \hat{\beta}_4^{(2)}, \hat{\beta}_1^{(3)}, \dots, \hat{\beta}_4^{(3)}$$

dengan masing-masing *standart error* (SE) serta diperoleh data series $N_t^{(i)}$. Metode estimasi parameter yang digunakan adalah OLS dan GLS.

- c. Melakukan pengujian apakah residual dari langkah 3b telah memenuhi asumsi *white noise*. Apabila residual telah memenuhi asumsi *white noise* maka model yang digunakan adalah model *time series regression* dan melanjutkan langkah analisis ke langkah nomor 8. Apabila residual belum memenuhi asumsi *white noise*, maka dapat dilanjutkan ke langkah analisis nomor 4.
4. Memodelkan residual yang diperoleh dari regresi *time series* dengan menggunakan VAR dan GSTAR dengan tahapan identifikasi, estimasi, dan cek diagnosa sehingga diperoleh orde untuk kedua data *inflow* dan *outflow* adalah VAR(1) dan GSTAR(1₁) dengan bobot seragam, inver jarak, dan NIKSP. Maka diperoleh persamaan berikut untuk data *inflow* dan *outflow*
Berikut untuk VAR(1),

$$\begin{aligned}
N_t^{(1)} &= \phi_{11}N_{t-1}^{(1)} + \phi_{12}N_{t-1}^{(2)} + \phi_{13}N_{t-1}^{(3)} + a_t^{(1)} \\
N_t^{(2)} &= \phi_{21}N_{t-1}^{(1)} + \phi_{22}N_{t-1}^{(2)} + \phi_{23}N_{t-1}^{(3)} + a_t^{(2)} \\
N_t^{(3)} &= \phi_{31}N_{t-1}^{(1)} + \phi_{32}N_{t-1}^{(2)} + \phi_{33}N_{t-1}^{(3)} + a_t^{(3)}.
\end{aligned} \tag{3.24}$$

Dan untuk GSTAR(1₁)

$$\begin{aligned}
N_t^{(1)} &= \phi_{10}N_{t-1}^{(1)} + \phi_{11}w_{12}N_{t-1}^{(2)} + \phi_{11}w_{13}N_{t-1}^{(3)} + a_t^{(1)} \\
N_t^{(2)} &= \phi_{20}N_{t-1}^{(2)} + \phi_{21}w_{21}N_{t-1}^{(1)} + \phi_{21}w_{23}N_{t-1}^{(3)} + a_t^{(2)} \\
N_t^{(3)} &= \phi_{30}N_{t-1}^{(3)} + \phi_{31}w_{31}N_{t-1}^{(1)} + \phi_{31}w_{32}N_{t-1}^{(2)} + a_t^{(3)}.
\end{aligned} \tag{3.25}$$

Sehingga dapat dimodelkan dalam bentuk

$$\begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix} = \begin{pmatrix} X^{(1)*} \beta^{(1)*} + a_t^{(1)} \\ X^{(2)*} \beta^{(2)*} + a_t^{(2)} \\ X^{(3)*} \beta^{(3)*} + a_t^{(3)} \end{pmatrix} \tag{3.26}$$

$$\mathbf{N} = \mathbf{X}^* \boldsymbol{\beta}^* + \mathbf{a} \tag{3.27}$$

dengan

$$\mathbf{N} = \begin{pmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{pmatrix}, \mathbf{X}^* = \begin{pmatrix} X^{(1)*} & 0 & 0 \\ 0 & X^{(2)*} & 0 \\ 0 & 0 & X^{(3)*} \end{pmatrix}, \boldsymbol{\beta}^* = \begin{pmatrix} \beta^{(1)*} \\ \beta^{(2)*} \\ \beta^{(3)*} \end{pmatrix}, \mathbf{a} = \begin{pmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{pmatrix}$$

untuk VAR(1)

$$X^{(1)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(2)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(3)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$\beta^{(1)*} = (\phi_{11} \quad \phi_{12} \quad \phi_{13})',$$

$$\beta^{(2)*} = (\phi_{21} \quad \phi_{22} \quad \phi_{23})',$$

$$\beta^{(3)*} = (\phi_{31} \quad \phi_{32} \quad \phi_{33})'$$

dan berikut untuk GSTAR(1₁)

$$X^{(1)*} = \begin{pmatrix} N_{t-1}^{(1)} & N_{t-1}^{(2)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(2)*} = \begin{pmatrix} N_{t-1}^{(2)} & N_{t-1}^{(1)} & N_{t-1}^{(3)} \end{pmatrix},$$

$$X^{(3)*} = \begin{pmatrix} N_{t-1}^{(3)} & N_{t-1}^{(1)} & N_{t-1}^{(2)} \end{pmatrix},$$

$$\beta^{(1)*} = (\phi_{10} \quad \phi_{11}w_{12} \quad \phi_{11}w_{13})',$$

$$\beta^{(1)*} = (\phi_{20} \quad \phi_{21}w_{21} \quad \phi_{21}w_{23})',$$

$$\beta^{(1)*} = (\phi_{30} \quad \phi_{31}w_{31} \quad \phi_{11}w_{32})'.$$

Maka didapatkan $\hat{\phi}_{11}, \hat{\phi}_{12}, \hat{\phi}_{13}, \hat{\phi}_{21}, \hat{\phi}_{22}, \hat{\phi}_{23}, \hat{\phi}_{31}, \hat{\phi}_{32}, \hat{\phi}_{33}$ untuk VAR(1) dan $\hat{\phi}_{10}, \hat{\phi}_{20}, \hat{\phi}_{30}, \hat{\phi}_{11}, \hat{\phi}_{21}, \hat{\phi}_{31}$ untuk GSTAR(1₁) dengan masing-masing *standart error* (SE) serta diperoleh data series $a_t^{(i)}$. Estimasi parameter GSTAR(1₁) menggunakan metode OLS dan GLS

5. Melakukan pemeriksaan apakah data mengandung unsur non linieritas menggunakan pengujian *Terasvirta*.
6. Apabila terdapat unsur non linier pada data, maka dilanjutkan ke langkah nomor 7. Apabila tidak terdapat unsur non linieritas maka dapat dilanjutkan ke langkah nomor 8.
7. Memodelkan residual yang diperoleh dari model level satu menggunakan SVR sehingga diperoleh model *Hybrid VARX-SVR* dan *Hybrid GSTARX-SVR*. Tahapan yang dilakukan adalah sebagai berikut:
 - a. Menentukan variabel *input* yang akan digunakan dalam SVR. Penentuan variabel *input* yang digunakan sama dengan *input* model VARX dan GSTARX.

$$N_t^{(1)} = \sum_{t=1}^n (\beta_t - \beta_t^*) K(x_t, \mathbf{x}) + b^{(1)},$$

$$N_t^{(2)} = \sum_{t=1}^n (\beta_t - \beta_t^*) K(x_t, \mathbf{x}) + b^{(2)},$$


$$N_t^{(3)} = \sum_{t=1}^n (\beta_t - \beta_t^*) K(x_t, \mathbf{x}) + b^{(3)},$$

Dengan fungsi Kernel *Radial Basis Function* seperti pada persamaan 2.87 subbab 2.6.1


- b. Menentukan fungsi kernel, nilai-nilai parameter kernel dan parameter *cost* dari parameter epsilon untuk optimasi *hyperplane* pada data *training*.
- c. Memilih nilai parameter terbaik menggunakan metode *grid-search* pada tiap *hyperplane* dengan cara sebagai berikut:

- i. Optimasi parameter α dan β
 - ii. Menggunakan *hyperplane-hyperplane* tersebut untuk tiap model regresi
 - iii. Hitung *error* tiap model regresi
 - iv. Hitung rata-rata *error* hasil regresi untuk setiap *hyperplane*.
 - v. Menentukan *hyperplane* terbaik.
 - d. Menggunakan *hyperplane* dengan parameter terbaik yang diperoleh pada regresi data *testing*
 - e. Estimasi nilai RMSE.
8. Melakukan peramalan titik untuk data *testing* menggunakan metode yang diperoleh pada langkah sebelumnya, kemudian menghitung tingkat kesalahan peramalan untuk data *testing*.
 9. Menarik kesimpulan dan merumuskan saran.

Langkah-langkah analisis tersebut dapat digambarkan dalam diagram alir pada Gambar 3.2 dan Gambar 3.3.




Gambar 3. 2 Tahapan dalam kajian simulasi.



Gambar 3. 3 Tahapan dalam kajian terapan


Pembentukan model dapat diilustrasikan kedalam gambar berikut,

1. Pembentukan Model GSTARX dan VARX



Gambar 3. 4 Ilustrasi Pembentukan Model GSTARX dan VARX

2. Pembentukan Model Hybrid GSTARX-SVR dan Hybrid VARX-SVR



Gambar 3. 5 Ilustrasi Pembentukan Model *Hybrid* GSTARX-SVR dan Hybrid VARX-SVR

BAB 4

ANALISIS DAN PEMBAHASAN

Pada bagian ini dilakukan analisis dan pembahasan studi simulasi dan terapan pada data *inflow* dan *outflow* Bank Indonesia KPW II (Jawa Barat). Metode analisis yang digunakan adalah VARX, VARX-SVR, GSTARX dan GSTARX-SVR. Secara lengkap berikut ini dijelaskan hasil analisis dan pembahasan.

4.1 Pemodelan Data Simulasi

Studi simulasi dalam penelitian ini menggunakan model VARX, VARX-SVR, GSTARX(1₁) dan GSTARX-SVR. Metode estimasi yang digunakan untuk model GSTARX(1₁) yaitu OLS dan GLS. Nantinya akan dilakukan perbandingan untuk mengetahui metode estimasi yang lebih baik dalam skenario residual yang saling berkorelasi (tidak *white noise*). Variabel *dummy* yang digunakan pada studi simulasi adalah tren deterministik, pola musiman dan efek variasi kalender.

Data simulasi dibangkitkan mengikuti pola vektor AR (1) dan menambahkan prediktor *X* sebagai input dalam bentuk variabel *dummy* dari tren deterministik, pola musiman dan efek variasi kalender. Pemodelan level satu dilakukan menggunakan model TSR (*Time Series Regression*). Untuk kemudian residual TSR dimodelkan dengan GSTAR pada level dua. Model GSTARX (1₁) dua level dalam bentuk matriks dengan tiga lokasi dapat ditulis.

- Untuk level satu

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} = \begin{bmatrix} \alpha_{1,1} & 0 & 0 \\ 0 & \alpha_{2,1} & 0 \\ 0 & 0 & \alpha_{3,1} \end{bmatrix} \begin{bmatrix} T_t^{(1)} \\ T_t^{(2)} \\ T_t^{(3)} \end{bmatrix} + \begin{bmatrix} \gamma_{1,s} & 0 & 0 \\ 0 & \gamma_{2,s} & 0 \\ 0 & 0 & \gamma_{3,s} \end{bmatrix} \begin{bmatrix} S_t^{(1)} \\ S_t^{(2)} \\ S_t^{(3)} \end{bmatrix} + \begin{bmatrix} \delta_{1,v} & 0 & 0 \\ 0 & \gamma_{2,v} & 0 \\ 0 & 0 & \gamma_{3,v} \end{bmatrix} \begin{bmatrix} M_t^{(1)} \\ M_t^{(2)} \\ M_t^{(3)} \end{bmatrix} + \begin{bmatrix} \beta_{1,v} & 0 & 0 \\ 0 & \beta_{2,v} & 0 \\ 0 & 0 & \beta_{3,v} \end{bmatrix} \begin{bmatrix} M_{t-1}^{(1)} \\ M_{t-1}^{(2)} \\ M_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix}, \quad (4.1)$$

dengan $s = 1, 2, 3, \dots, 12$ dan $v = 1, 2, 3, 4$.

- Untuk level dua

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \left(\begin{bmatrix} \varphi_{10} & 0 & 0 \\ 0 & \varphi_{20} & 0 \\ 0 & 0 & \varphi_{30} \end{bmatrix} + \begin{bmatrix} \varphi_{11} & 0 & 0 \\ 0 & \varphi_{21} & 0 \\ 0 & 0 & \varphi_{31} \end{bmatrix} \right) \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}. \quad (4.2)$$

dan

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \left(\begin{bmatrix} \varphi_{10} & 0 & 0 \\ 0 & \varphi_{20} & 0 \\ 0 & 0 & \varphi_{30} \end{bmatrix} + \begin{bmatrix} \varphi_{11} & 0 & 0 \\ 0 & \varphi_{21} & 0 \\ 0 & 0 & \varphi_{31} \end{bmatrix} \begin{bmatrix} 0 & w_{12} & w_{13} \\ w_{21} & 0 & w_{23} \\ w_{31} & w_{32} & 0 \end{bmatrix} \right) \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}. \quad (4.3)$$

Selanjutnya, model VARX dan GSTARX dua level akan ditulis dalam bentuk


$$\begin{aligned} \begin{bmatrix} Z_t^{(1)} \\ Z_t^{(2)} \\ Z_t^{(3)} \end{bmatrix} &= \begin{bmatrix} \varphi_{11}^* & \varphi_{12}^* & \varphi_{13}^* \\ \varphi_{21}^* & \varphi_{22}^* & \varphi_{23}^* \\ \varphi_{31}^* & \varphi_{32}^* & \varphi_{33}^* \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} \alpha_{1,1} & 0 & 0 \\ 0 & \alpha_{2,1} & 0 \\ 0 & 0 & \alpha_{3,1} \end{bmatrix} \begin{bmatrix} T_t^{(1)} \\ T_t^{(2)} \\ T_t^{(3)} \end{bmatrix} + \\ &\begin{bmatrix} \gamma_{1,s} & 0 & 0 \\ 0 & \gamma_{2,s} & 0 \\ 0 & 0 & \gamma_{3,s} \end{bmatrix} \begin{bmatrix} S_t^{(1)} \\ S_t^{(2)} \\ S_t^{(3)} \end{bmatrix} + \begin{bmatrix} \delta_{1,v} & 0 & 0 \\ 0 & \gamma_{2,v} & 0 \\ 0 & 0 & \gamma_{3,v} \end{bmatrix} \begin{bmatrix} M_t^{(1)} \\ M_t^{(2)} \\ M_t^{(3)} \end{bmatrix} + \\ &\begin{bmatrix} \beta_{1,v} & 0 & 0 \\ 0 & \beta_{2,v} & 0 \\ 0 & 0 & \beta_{3,v} \end{bmatrix} \begin{bmatrix} M_{t-1}^{(1)} \\ M_{t-1}^{(2)} \\ M_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix} \end{aligned} \quad (4.4)$$

dengan $\phi_{ii}^* = \phi_{i0}$, dan $\phi_{ij}^* = w_{ij}\phi_{i1}$ untuk $i \neq j$. Model dari persamaan (4.4) akan dilakukan estimasi dengan dua level. **Level satu**, estimasi dilakukan hanya untuk parameter tren deterministik, pola musiman dan efek variasi kalender, sedangkan estimasi **level dua** dilakukan pada parameter antar lokasi (spasial). Pemodelan data simulasi akan dilakukan dengan dua skenario seperti yang telah dijelaskan pada Bab 3, yaitu dengan skenario residual bersifat linier dan residual bersifat non linier. Berikut hasil dan pembahasan dari kedua studi simulasi tersebut.

4.1.1 Pemodelan Residual Linier (Skenario 1)

Desain simulasi data bangkitan dengan residual bersifat linier dengan tiga lokasi ditunjukkan pada Gambar 4.1. Plot *time series* menunjukkan model vektor AR(1) dengan data yang mengandung tren deterministik, pola musiman dan efek variasi kalender. **Tahap satu** dalam analisis ini adalah melakukan pemodelan level satu, yaitu regresi *time series*. Tren deterministik dan variabel *dummy* dari


pola musiman dan efek variasi kalender digunakan sebagai variabel prediktor. Pada tahap ini akan digunakan metode estimasi OLS dan GLS.



Gambar 4.1 Plot *Time Series* Data Simulasi Residual Linier di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3.

Hasil estimasi parameter pada level satu ditunjukkan pada Lampiran 1 Tabel A. Terlihat bahwa metode estimasi OLS dan GLS menghasilkan nilai standar *error* dari parameter yang bernilai sama, sehingga efisiensi GLS untuk model ini tidak ada.

Untuk mengetahui apakah hasil estimasi parameter pada level satu telah benar dengan nilai parameter yang telah ditetapkan sebelumnya seperti persamaan (3.1), maka dapat dilihat melalui *Confidence Interval* (CI) 95% dengan batas $\hat{\phi}_{ij} \pm (t_{\alpha/2; n-2} \cdot SE(\hat{\phi}_{ij}))$ seperti pada Lampiran 1 Tabel B. Boxplot pada Gambar 4.2 memperlihatkan hasil estimasi level satu model TSR dengan replikasi 10 kali. Terlihat bahwa semua nilai parameter sebenarnya berada di dalam selang CI estimasi parameter. Hal ini menunjukkan estimasi parameter sudah benar dengan nilai parameter yang sebenarnya.



Gambar 4. 2 Boxplot Koefisien Estimasi Parameter dengan Nilai Sebenarnya dengan CI 95% untuk Parameter (a) Tren, (b) Variasi Kalender dan (c) Musiman.

Selanjutnya, hasil estimasi parameter model untuk level satu dapat dituliskan sebagai berikut.

i. Model TSR di lokasi satu

$$\begin{aligned}
 Y_t^{(1)*} = & 0,21T_t^{(1)} + 22,02S_{1,t}^{(1)} + 23,97S_{2,t}^{(1)} + 27,01S_{3,t}^{(1)} + 24,12S_{4,t}^{(1)} + \\
 & 22,1S_{5,t}^{(1)} + 17,18S_{6,t}^{(1)} + 13,52S_{7,t}^{(1)} + 10,26S_{8,t}^{(1)} + 6,24S_{9,t}^{(1)} + \\
 & 10,03S_{10,t}^{(1)} + 13,20S_{11,t}^{(1)} + 17,13S_{12,t}^{(1)} + 32,41M_{1,t}^{(1)} + 43,57M_{2,t}^{(1)} + \\
 & 46,44M_{3,t}^{(1)} + 48,61M_{4,t}^{(1)} + 49,91M_{1,t-1}^{(1)} + 46,39M_{2,t-1}^{(1)} + \\
 & 38,72M_{3,t-1}^{(1)} + 32,34M_{4,t-1}^{(1)} + N_t^{(1)}.
 \end{aligned} \tag{4.5}$$


ii. Model TSR di lokasi dua

$$\begin{aligned}
 Y_t^{(2)*} = & 0,23_t^{(2)} + 25,09S_{1,t}^{(2)} + 28,09S_{2,t}^{(2)} + 30,29S_{3,t}^{(2)} + 28,15S_{4,t}^{(2)} + \\
 & 25S_{5,t}^{(2)} + 21,33S_{6,t}^{(2)} + 16,41S_{7,t}^{(2)} + 13,24S_{8,t}^{(2)} + 9,21S_{9,t}^{(2)} + 13,26S_{10,t}^{(2)} + \\
 & 16,07S_{11,t}^{(2)} + 21,11S_{12,t}^{(2)} + 45,39M_{1,t}^{(2)} + 49,71M_{2,t}^{(2)} + 54,15M_{3,t}^{(2)} + \\
 & 56,71M_{4,t}^{(2)} + 59,61M_{1,t-1}^{(2)} + 54,31M_{2,t-1}^{(2)} + 45,48M_{3,t-1}^{(2)} + 35,9M_{4,t-1}^{(2)} + \\
 & N_t^{(2)}.
 \end{aligned} \tag{4.6}$$

iii. Model TSR di lokasi tiga

$$\begin{aligned}
 Y_t^{(3)*} = & 0,24T_t^{(3)} + 17,21S_{1,t}^{(3)} + 21,14S_{2,t}^{(3)} + 24S_{3,t}^{(3)} + 21,1S_{4,t}^{(3)} + \\
 & 17,15S_{5,t}^{(3)} + 12,22S_{6,t}^{(3)} + 9,29S_{7,t}^{(3)} + 6,19S_{8,t}^{(3)} + 4,34S_{9,t}^{(3)} + \\
 & 6,22S_{10,t}^{(3)} + 9,21S_{11,t}^{(3)} + 12,24S_{12,t}^{(3)} + 37,42M_{1,t}^{(3)} + 40,56M_{2,t}^{(3)} + \\
 & 46,43M_{3,t}^{(3)} + 50,75M_{4,t}^{(3)} + 48,9M_{1,t-1}^{(3)} + 47,2M_{2,t-1}^{(3)} + \\
 & 40,6M_{3,t-1}^{(3)} + 36,48M_{4,t-1}^{(3)} + N_t^{(3)}.
 \end{aligned} \tag{4.7}$$

Dari hasil pemodelan level satu pada persamaan (4.5)–(4.7) diperoleh residual $N_t^{(i)}$. Residual ini kemudian digunakan sebagai input dalam pemodelan level dua, yaitu model GSTAR yang nantinya didapatkan parameter antar lokasi (spasial). *Series* residual $N_t^{(i)}$ ditunjukkan pada Gambar 4.3.



Gambar 4. 3 Plot *Time Series* Residual Data Simulasi Skenario Satu untuk (a) Lokasi 1, (b) Lokasi 2 Dan (c) Lokasi 3.

Terlihat pada Gambar 4.3 residual dari ketiga lokasi menunjukkan kondisi yang stasioner, artinya berada disekitar $\mu = 0$. Pemeriksaan stasioneritas pada **tahap dua** juga dapat dilihat melalui skematik MCCF pada Gambar 4.4. **Tahap tiga**, adalah melakukan pemodelan VAR untuk memodelkan hubungan antar lokasi. Pertama tama dilakukan pemeriksaan orde AR(1) melalui skematik MPCCF dan nilai AIC minimum pada Gambar 4.5 dan Tabel 4.1.

Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14
zresid11	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++
zresid21	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++
zresid31	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++	+++
Lag	15	16	17	18	19	20									
zresid11	+++	+++									
zresid21	+++									
zresid31	+++									

Gambar 4. 4 Representasi Skematik MCCF Skenario 1 untuk Ketiga Lokasi.

Pada Gambar 4.4 terlihat bahwa model VAR telah menunjukkan kondisi yang stasioner. Walaupun tanda plus muncul hingga lag 15, namun hal ini merupakan kondisi yang stasioner dikarenakan *eigenvalue* dari parameter bangkitan mendekati satu, selain itu jumlah data bangkitan yang cukup besar. Nilai AIC pada Tabel 4.1 menunjukkan bahwa model yang terbentuk adalah benar pada VAR (1). Hal ini ditunjukkan oleh nilai minimum terdapat pada orde AR (1) dan MA (0).

Tabel 4. 1 Nilai AIC Residual TSR Skenario 1.

Lag	MA(0)	MA(1)	MA(2)	MA(3)	MA(4)	MA(5)
AR(0)	-1,254	-1,448	-1,603	-1,704	-1,788	-1,932
AR(1)	-2,954	-2,936	-2,927	-2,918	-2,900	-2,870
AR(2)	-2,944	-2,922	-2,930	-2,898	-2,860	-2,822
AR(3)	-2,934	-2,919	-2,900	-2,864	-2,836	-2,830
AR(4)	-2,908	-2,882	-2,858	-2,832	-2,811	-2,791
AR(5)	-2,876	-2,863	-2,818	-2,821	-2,782	-2,754

Pemeriksaan orde waktu dari model VAR dapat pula dilakukan dengan melihat skematik MPCCF seperti pada Gambar 4.5.

Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
zresid11	+++
zresid21	+++
zresid31	+++

Gambar 4. 5 Representasi Skematik MPCCF Simulasi Skenario 1.

Skematik MPCCF menunjukkan bahwa tanda positif (+) yang muncul pada ketiga lokasi hanya pada lag ke-1, artinya data simulasi dari ketiga lokasi adalah benar pada VAR(1). Matriks varians kovarians pada persamaan (3.1) dapat pula ditunjukkan dengan melihat skematik korelasi silang residual seperti pada Gambar 4.6.

Variable/ Lag	0	1	2	3
zresid11	+++
zresid21	+++
zresid31	+++	-. -

Gambar 4. 6 Representasi Skematik MCCF Residual Simulasi Skenario 1.

Matriks varians kovarians dengan diagonal utama pada lag ke-0 menunjukkan tanda positif (+), artinya terdapat nilai varians dari ketiga lokasi. Studi simulasi pada skenario kesatu ini nilai varians yang diberikan adalah sama. Selain diagonal utama pada lag ke-0 juga menunjukkan tanda titik(+), artinya ada korelasi antar lokasi. Hasil estimasi parameter model VAR (1) ditunjukkan pada Lampiran 1 Tabel C. Maka model VAR (1) yang diperoleh adalah

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,2781 & 0,2858 & 0,3784 \\ 0,1185 & 0,4208 & 0,4431 \\ 0,1339 & 0,1971 & 0,4802 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix} \quad (4.8)$$

i. Lokasi satu

$$N_t^{(1)*} = 0,2781N_{t-1}^{(1)} + 0,2858N_{t-1}^{(2)} + 0,3784N_{t-1}^{(3)} + a_t^{(1)} \quad (4.9)$$

ii. Lokasi dua

$$N_t^{(2)*} = 0,1185N_{t-1}^{(1)} + 0,4208N_{t-1}^{(2)} + 0,4431N_{t-1}^{(3)} + a_t^{(2)} \quad (4.10)$$

iii. Lokasi tiga

$$N_t^{(3)*} = 0,1339N_{t-1}^{(1)} + 0,1971N_{t-1}^{(2)} + 0,4802N_{t-1}^{(3)} + a_t^{(3)} \quad (4.11)$$

Tahap empat adalah menentukan bobot spasial pada masing-masing lokasi. Metode pembobotan spasial yang digunakan pada simulasi ini dibatasi pada bobot seragam. Namun nantinya pada kajian terapan dimungkinkan menggunakan bobot lain yang terbaik, salah satunya Normalisasi Inferensi Korelasi Silang Parsial. Bobot ini diperoleh berdasarkan tinggi rendahnya nilai korelasi silang parsial antar lokasi. Hasil perhitungan parsial korelasi silang antar lokasi pada lag waktu ke-1, atau $r_{ij}(1)$ dengan $i, j = 1, 2, 3$ dan $i \neq j$ dapat dilihat pada Tabel 4.2. Proses inferensia statistik dilakukan dengan menggunakan taksiran interval 95%. Berdasarkan perhitungan dari hasil besaran korelasi silang antar lokasi pada waktu ke-1, proses inferensia statistik pada Tabel 4.2 menunjukkan bahwa taksiran interval menghasilkan batas yang sama (tanda


hubungan), sehingga memberikan keputusan valid dan sebanding, artinya ada perbedaan untuk pemberian bobot antar lokasi. Metode pembobotan yang sesuai pada skenario ini adalah selain bobot seragam.

Tabel 4. 2 Taksiran NIKSP Simulasi Skenario 1.

Parameter	Estimasi	Taksiran interval 95%		Keputusan
		Batas bawah	Batas atas	
P ₁₂ (1)	0,295	0,195	0,395	Valid dan sebanding
P ₁₃ (1)	0,214	0,114	0,314	Valid dan sebanding
P ₂₁ (1)	0,254	0,154	0,355	Valid dan sebanding
P ₂₃ (1)	0,161	0,061	0,261	Valid dan sebanding
P ₃₁ (1)	0,210	0,110	0,310	Valid dan sebanding
P ₃₂ (1)	0,346	0,246	0,446	Valid dan sebanding

Tahap lima adalah melakukan estimasi parameter di level dua, model GSTAR. Pada tahap ini akan digunakan metode estimasi OLS dan GLS. Hasil estimasi parameter model GSTARX (1₁) pada level dua seperti ditunjukkan pada Lampiran 1 Tabel F. Terlihat bahwa terdapat efisiensi GLS, hal ini sesuai desain simulasi yang diberikan. Secara umum, untuk skenario residual saling berkorelasi antar lokasi metode estimasi OLS dan GLS akan menghasilkan nilai standar *error* dari parameter yang berbeda.

Untuk mengetahui apakah hasil estimasi parameter pada level dua telah benar dengan nilai parameter yang telah ditetapkan sebelumnya seperti persamaan (3.1), maka dapat dilihat melalui *Confidence Interval* (CI) 95% dengan batas $\hat{\phi}_{ij} \pm (t_{\alpha/2; n-2} \cdot SE(\hat{\phi}_{ij}))$ seperti pada Lampiran 1 Tabel G yang disajikan dalam Gambar 4.7. Terlihat bahwa dari hasil estimasi level dua, model GSTAR untuk semua parameter sudah benar dengan nilai parameter yang sebenarnya.



Gambar 4. 7 Boxplot Koefisien Parameter Level Dua Model GSTAR-GLS Skenario 1.

Selanjutnya, hasil estimasi parameter model GSTARX (1₁) untuk level dua dapat dituliskan sebagai berikut.

a. GSTAR (1₁)-OLS

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,288 & 0,324 & 0,324 \\ 0,246 & 0,458 & 0,246 \\ 0,164 & 0,164 & 0,481 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix} \quad (4.12)$$

i. Lokasi satu

$$N_t^{(1)*} = 0,288N_{t-1}^{(1)} + 0,324N_{t-1}^{(2)} + 0,324N_{t-1}^{(3)} + a_t^{(1)} \quad (4.13)$$

ii. Lokasi dua

$$N_t^{(2)*} = 0,246N_{t-1}^{(1)} + 0,458N_{t-1}^{(2)} + 0,246N_{t-1}^{(3)} + a_t^{(2)} \quad (4.14)$$

iii. Lokasi tiga

$$N_t^{(3)*} = 0,164N_{t-1}^{(1)} + 0,164N_{t-1}^{(2)} + 0,481N_{t-1}^{(3)} + a_t^{(3)}. \quad (4.15)$$

Sehingga, model GSTARX (1₁)-OLS level satu dan dua dapat dituliskan

$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,288 & 0,324 & 0,324 \\ 0,246 & 0,458 & 0,246 \\ 0,164 & 0,164 & 0,481 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,21 & 0 & 0 \\ 0 & 0,23 & 0 \\ 0 & 0 & 0,24 \end{bmatrix} \begin{bmatrix} T_t^{(1)} \\ T_t^{(2)} \\ T_t^{(3)} \end{bmatrix} + \begin{bmatrix} 22,02 & 0 & 0 \\ 0 & 25,09 & 0 \\ 0 & 0 & 17,21 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 17,13 & 0 & 0 \\ 0 & 21,11 & 0 \\ 0 & 0 & 12,24 \end{bmatrix} \begin{bmatrix} S_{12,t}^{(1)} \\ S_{12,t}^{(2)} \\ S_{12,t}^{(3)} \end{bmatrix} + \begin{bmatrix} 32,41 & 0 & 0 \\ 0 & 45,39 & 0 \\ 0 & 0 & 37,42 \end{bmatrix} \begin{bmatrix} M_{1,t}^{(1)} \\ M_{1,t}^{(2)} \\ M_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 48,61 & 0 & 0 \\ 0 & 56,71 & 0 \\ 0 & 0 & 50,75 \end{bmatrix} \begin{bmatrix} M_{4,t}^{(1)} \\ M_{4,t}^{(2)} \\ M_{4,t}^{(3)} \end{bmatrix} + \begin{bmatrix} 49,91 & 0 & 0 \\ 0 & 59,61 & 0 \\ 0 & 0 & 48,9 \end{bmatrix} \begin{bmatrix} M_{1,t-1}^{(1)} \\ M_{1,t-1}^{(2)} \\ M_{1,t-1}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 33,34 & 0 & 0 \\ 0 & 35,9 & 0 \\ 0 & 0 & 36,48 \end{bmatrix} \begin{bmatrix} M_{4,t-1}^{(1)} \\ M_{4,t-1}^{(2)} \\ M_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}$$

b. GSTAR(1₁)-GLS

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,357 & 0,285 & 0,285 \\ 0,249 & 0,452 & 0,249 \\ 0,211 & 0,211 & 0,370 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix} \quad (4.16)$$

i. Lokasi satu

$$N_t^{(1)*} = 0,357N_{t-1}^{(1)} + 0,285N_{t-1}^{(2)} + 0,285N_{t-1}^{(3)} + a_t^{(1)} \quad (4.17)$$

ii. Lokasi dua

$$N_t^{(2)*} = 0,249N_{t-1}^{(1)} + 0,452N_{t-1}^{(2)} + 0,249N_{t-1}^{(3)} + a_t^{(2)} \quad (4.18)$$

iii. Lokasi tiga

$$N_t^{(3)*} = 0,211N_{t-1}^{(1)} + 0,211N_{t-1}^{(2)} + 0,370N_{t-1}^{(3)} + a_t^{(3)}. \quad (4.19)$$

Dapat dituliskan dalam bentuk matriks sebagai berikut,


$$\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,357 & 0,285 & 0,285 \\ 0,249 & 0,452 & 0,249 \\ 0,211 & 0,211 & 0,370 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,21 & 0 & 0 \\ 0 & 0,23 & 0 \\ 0 & 0 & 0,24 \end{bmatrix} \begin{bmatrix} T_t^{(1)} \\ T_t^{(2)} \\ T_t^{(3)} \end{bmatrix} +$$

$$\begin{bmatrix} 22,02 & 0 & 0 \\ 0 & 25,09 & 0 \\ 0 & 0 & 17,21 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 17,13 & 0 & 0 \\ 0 & 21,11 & 0 \\ 0 & 0 & 12,24 \end{bmatrix} \begin{bmatrix} S_{12,t}^{(1)} \\ S_{12,t}^{(2)} \\ S_{12,t}^{(3)} \end{bmatrix} +$$


$$\begin{bmatrix} 32,41 & 0 & 0 \\ 0 & 45,39 & 0 \\ 0 & 0 & 37,42 \end{bmatrix} \begin{bmatrix} M_{1,t}^{(1)} \\ M_{1,t}^{(2)} \\ M_{1,t}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 48,61 & 0 & 0 \\ 0 & 56,71 & 0 \\ 0 & 0 & 50,75 \end{bmatrix} \begin{bmatrix} M_{4,t}^{(1)} \\ M_{4,t}^{(2)} \\ M_{4,t}^{(3)} \end{bmatrix} +$$

$$\begin{bmatrix} 49,91 & 0 & 0 \\ 0 & 59,61 & 0 \\ 0 & 0 & 48,9 \end{bmatrix} \begin{bmatrix} M_{1,t-1}^{(1)} \\ M_{1,t-1}^{(2)} \\ M_{1,t-1}^{(3)} \end{bmatrix} + \dots + \begin{bmatrix} 33,34 & 0 & 0 \\ 0 & 35,9 & 0 \\ 0 & 0 & 36,48 \end{bmatrix} \begin{bmatrix} M_{4,t-1}^{(1)} \\ M_{4,t-1}^{(2)} \\ M_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}$$

Selanjutnya, untuk melihat konsistensi dari hasil estimasi perlu dilakukan replikasi. Pada penelitian ini proses replikasi dibatasi dengan melakukan sebanyak 10 kali dengan data yang berbeda, namun tetap sesuai dengan pola vektor AR(1) dan dengan nilai koefisien setiap parameter seperti persamaan (3.1).




Gambar 4. 8 Koefisien Parameter ϕ_{10}^1 (kiri) dan ϕ_{11}^1 (kanan) Model GSTAR Setiap Replikasi Simulasi Skenario 1 (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3




Gambar 4.8 (lanjutan)

Pada Gambar 4.8, dari hasil replikasi sebanyak 10 kali yang telah dilakukan, secara visual terlihat bahwa secara umum nilai koefisien hasil estimasi parameter model GSTAR sudah baik, hal ini terlihat dari tidak ada lebih dari 3 replikasi yang tidak benar dengan nilai sebenarnya. Seperti diketahui, dalam studi simulasi adalah dengan menggunakan konsep *trial and error*, inilah yang menyebabkan hasil replikasi ke-1 belum tentu sama baiknya dengan replikasi ke- r .




Gambar 4. 9 Standar *Error* Metode OLS dan GLS Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Setiap Replikasi Simulasi Skenario 1, (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3.

Gambar 4.9 menunjukkan bahwa dari hasil replikasi sebanyak 10 kali, secara visual terlihat metode estimasi GLS selalu menghasilkan nilai standar *error* yang lebih kecil daripada estimasi OLS. Secara visual, perbandingan hasil estimasi dengan metode OLS dan GLS ditunjukkan melalui kurva pdf dari setiap parameter pada Gambar 4.10. Terlihat bahwa metode GLS terlihat lebih efisien dibandingkan OLS, hal ini terlihat dari bentuk kurva yang lebih sempit.



Gambar 4. 10 Plot Distribusi Parameter ϕ_{i0}^1 (kiri) dan ϕ_{i1}^1 (kanan) Metode Estimasi OLS dan GLS Data Simulasi 3 (a) Lokasi 1, (b) Lokasi 2, dan (c) Lokasi 3 Skenario 1

Tahap keenam, adalah melakukan pemodelan non linier. Residual yang diperoleh dari tahap satu dapat disajikan dalam matriks plot pada Gambar 4.11.



Gambar 4. 11 Matriks Plot Residual TSR pada Simulasi Residual Linier

Matriks plot pada Gambar 4.11 menunjukkan residual tahap pertama mengandung pola linier. Namun tetap akan dilakukan pemodelan non linier untuk nantinya dibandingkan mana yang lebih baik. Maka selanjutnya dilakukan pemodelan non linier dengan VARX-SVR dan GSTARX-SVR. Pemodelan *hybrid* SVR pada penelitian ini menggunakan metode *grid search* dalam penentuan parameter yang digunakan. hal ini bertujuan untuk mendapatkan hasil yang global optimum. Parameter yang dimiliki model SVR ada tiga yaitu parameter epsilon, sigma, dan *cost*, untuk mendapatkan parameter yang optimum perlu dilakukan kombinasi nilai dari ketiga parameter agar didapatkan nilai RMSE yang terkecil. Hasil pemodelan SVR yang baik akan menghasilkan nilai RMSE pada data *out sample* yang terkecil. Pemodelan GSTARX-SVR untuk masing-masing lokasi dilakukan secara terpisah.

Kombinasi nilai parameter yang digunakan adalah yang pertama untuk parameter epsilon digunakan rentang nilai antara 0,00005 sampai dengan 0.00009 dengan selisih nilai 10^{-5} . Parameter *cost* digunakan nilai antara 350 sampai 355 dengan selisih nilai 0,1. Sedangkan untuk nilai sigma digunakan nilai antara 0,05 sampai dengan 0,1 dengan selisih nilai 0,01. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Lampiran 1 Tabel D dan H.

Tabel D menunjukkan nilai MAPE model VARX-SVR pada data *out sample* yang paling kecil untuk lokasi 1 adalah 0,686, yaitu dengan nilai epsilon 0,00007, nilai *cost* sebesar 350 dan nilai sigma sebesar 0,06. Pada lokasi 2, MAPE terkecil sebesar 0,8276, dengan nilai epsilon 0,00006, *cost* sebesar 354,8 dan sigma sebesar 0,07. Sedangkan untuk lokasi 3, MAPE terkecil sebesar 0,63646, dengan nilai epsilon 0,00008, *cost* sebesar 352,7 dan sigma sebesar 0,06.

Sehingga didapat persamaan VARX-SVR sebagai berikut,

i. Lokasi Satu

$$\begin{aligned}
 \hat{Y}_t^{(1)} &= \sum_{i=1}^{383} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 289,55 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + \\
 &350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) - 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{383} - \mathbf{x}\|^2\right) - 0,59
 \end{aligned} \tag{4.20}$$

ii. Lokasi Dua

$$\begin{aligned}
\hat{Y}_t^{(2)} &= \sum_{i=1}^{383} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= 354,8 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 354,8 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&\quad 354 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 354,8 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + \\
&\quad 354,8 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 354,8 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{383} - \mathbf{x}\|^2\right) - 0,32
\end{aligned} \tag{4.21}$$

iii. Lokasi Tiga

$$\begin{aligned}
\hat{Y}_t^{(3)} &= \sum_{i=1}^{383} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= 352,7 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 352,7 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&\quad 352,7 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 352,7 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + \\
&\quad 352,7 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) - 352,7 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{383} - \mathbf{x}\|^2\right) - 0,017
\end{aligned} \tag{4.22}$$

Tabel H menunjukkan nilai MAPE model GSTARX-SVR pada data *out sample* yang paling kecil untuk lokasi 1 adalah 0,70578, yaitu dengan nilai epsilon 0,00008, nilai *cost* sebesar 350,4 dan nilai sigma sebesar 0,08. Pada lokasi 2, MAPE terkecil sebesar 0,67705, dengan nilai epsilon 0,00005, *cost* sebesar 354,5 dan sigma sebesar 0,06. Sedangkan untuk lokasi 3, MAPE terkecil sebesar 0,59885, dengan nilai epsilon 0,00005, *cost* sebesar 354,9 dan sigma sebesar 0,05.

Sehingga didapat persamaan GSTARX-SVR sebagai berikut,

i. Lokasi Satu

$$\begin{aligned}
\hat{Y}_t^{(1)} &= \sum_{i=1}^{383} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= 350,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 350,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&\quad 350,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 350,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + \\
&\quad 350,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 350,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{383} - \mathbf{x}\|^2\right) - 0,59
\end{aligned} \tag{4.23}$$


ii. Lokasi Dua

$$\begin{aligned}
 \hat{Y}_t^{(2)} &= \sum_{i=1}^{383} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= 354,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 354,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &\quad 354,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 354,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + \\
 &\quad 354,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 354,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{383} - \mathbf{x}\|^2\right) - 0,839
 \end{aligned} \tag{4.24}$$

iii. Lokasi Tiga

$$\begin{aligned}
 \hat{Y}_t^{(3)} &= \sum_{i=1}^{383} (\beta_i - \beta_i^*) K(x_i, \mathbf{x}) + b \\
 &= 350,4 \exp\left(-\frac{1}{2(0,05)^2} \|x_1 - \mathbf{x}\|^2\right) + 350,4 \exp\left(-\frac{1}{2(0,05)^2} \|x_2 - \mathbf{x}\|^2\right) + \\
 &\quad 350,4 \exp\left(-\frac{1}{2(0,05)^2} \|x_3 - \mathbf{x}\|^2\right) + \dots - 350,4 \exp\left(-\frac{1}{2(0,05)^2} \|x_{381} - \mathbf{x}\|^2\right) + \\
 &\quad 350,4 \exp\left(-\frac{1}{2(0,05)^2} \|x_{382} - \mathbf{x}\|^2\right) - 350,4 \exp\left(-\frac{1}{2(0,05)^2} \|x_{383} - \mathbf{x}\|^2\right) - 1,003
 \end{aligned} \tag{4.25}$$

Maka didapatkan hasil peramalan pada data *training (in sample)* dan *testing (out sample)* seperti ditampilkan pada Gambar 4.12.




Gambar 4. 12 Time Series Hasil Peramalan Model VARX-SVR (1) dan GSTARX-SVR (2) di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3

Garis hitam pada Gambar 4.12 menunjukkan nilai yang sebenarnya, garis biru menunjukkan nilai hasil ramalan data *in-sample*. Sedangkan nilai merah menunjukkan nilai hasil ramalan data *out-sample*. Terlihat bahwa garis biru cenderung mengikuti pola dari garis hitam, begitu pula dengan garis merah. Hal ini menunjukkan model VARX-SVR dan GSTARX-SVR dengan parameter tersebut dapat memodelkan dengan baik.

4.1.2 Pemodelan Residual Non Linier (Skenario 2)

Secara umum, pemodelan pada bagian ini hampir sama dengan skenario 1, namun terdapat perbedaan pada sifat residual yang non linier. Desain simulasi data bangkitan dengan residual bersifat non linier dengan tiga lokasi ditunjukkan pada Gambar 4.13.



Gambar 4. 13 Plot *Time Series* Data Simulasi Residual Non linier

Tahap satu dalam analisis ini adalah melakukan pemodelan level satu, yaitu regresi *time series*. Tren deterministik dan variabel *dummy* dari pola musiman dan efek variasi kalender digunakan sebagai variabel prediktor. Pada tahap ini akan digunakan metode estimasi OLS dan GLS. Hasil estimasi parameter pada level satu ditunjukkan pada Lampiran 2 Tabel A. Dari Lampiran 2 Tabel A terlihat bahwa efisiensi GLS untuk model ini tidak ada, metode estimasi

OLS dan GLS menghasilkan nilai standar *error* dari parameter yang bernilai sama.

Untuk mengetahui apakah hasil estimasi parameter pada level satu telah benar dengan nilai parameter yang telah ditetapkan sebelumnya seperti persamaan (3.1), maka dapat dilihat melalui *Confidence Interval* (CI) 95% dengan batas $\hat{\phi}_{ij} \pm (t_{\alpha/2; n-2} \cdot \text{SE}(\hat{\phi}_{ij}))$ seperti pada Lampiran 2 Tabel B. Tabel B menunjukkan bahwa hasil estimasi level satu sudah benar dengan nilai parameter yang sebenarnya. Selanjutnya, hasil estimasi parameter model untuk level satu dapat dituliskan sebagai berikut.

- Untuk lokasi satu :

$$\begin{aligned} Y_t^{(1)*} = & 0,21T_t^{(1)} + 23,09S_{1,t}^{(1)} + 24,75S_{2,t}^{(1)} + 27,93S_{3,t}^{(1)} + 25,56S_{4,t}^{(1)} + \\ & 22,21S_{5,t}^{(1)} + 17,68S_{6,t}^{(1)} + 13,58S_{7,t}^{(1)} + 10,26S_{8,t}^{(1)} + 6,83S_{9,t}^{(1)} + \\ & 11,03S_{10,t}^{(1)} + 13,04S_{11,t}^{(1)} + 18,07S_{12,t}^{(1)} + 31,65M_{1,t}^{(1)} + 42,55M_{2,t}^{(1)} + \\ & 46,08M_{3,t}^{(1)} + 49,23M_{4,t}^{(1)} + 49,85M_{1,t-1}^{(1)} + 45,42M_{2,t-1}^{(1)} + \\ & 39,88M_{3,t-1}^{(1)} + 32,66M_{4,t-1}^{(1)} + N_t^{(1)}. \end{aligned} \quad (4.26)$$

-Untuk lokasi dua :


$$\begin{aligned} Y_t^{(2)*} = & 0,23T_t^{(2)} + 25,85S_{1,t}^{(2)} + 28,71S_{2,t}^{(2)} + 31,13S_{3,t}^{(2)} + 29,29S_{4,t}^{(2)} + \\ & 25,04S_{5,t}^{(2)} + 21,86S_{6,t}^{(2)} + 16,59S_{7,t}^{(2)} + 13,45S_{8,t}^{(2)} + 9,9S_{9,t}^{(2)} + \\ & 14,14S_{10,t}^{(2)} + 16,21S_{11,t}^{(2)} + 21,91S_{12,t}^{(2)} + 44,85M_{1,t}^{(2)} + 48,57M_{2,t}^{(2)} + \\ & 54,38M_{3,t}^{(2)} + 56,99M_{4,t}^{(2)} + 59,11M_{1,t-1}^{(2)} + 53,88M_{2,t-1}^{(2)} + \\ & 45,06M_{3,t-1}^{(2)} + 35,12M_{4,t-1}^{(2)} + N_t^{(2)}. \end{aligned} \quad (4.27)$$

-Untuk lokasi tiga :

$$\begin{aligned} Y_t^{(3)*} = & 0,24T_t^{(3)} + 17,99S_{1,t}^{(3)} + 21,78S_{2,t}^{(3)} + 24,85S_{3,t}^{(3)} + 22,34S_{4,t}^{(3)} + \\ & 17,2S_{5,t}^{(3)} + 12,85S_{6,t}^{(3)} + 9,52S_{7,t}^{(3)} + 6,39S_{8,t}^{(3)} + 5,01S_{9,t}^{(3)} + \\ & 7,13S_{10,t}^{(3)} + 9,37S_{11,t}^{(3)} + 13,01S_{12,t}^{(3)} + 36,79M_{1,t}^{(3)} + 39,78M_{2,t}^{(3)} + \\ & 46,29M_{3,t}^{(3)} + 51,11M_{4,t}^{(3)} + 48,64M_{1,t-1}^{(3)} + 46,58M_{2,t-1}^{(3)} + \\ & 41,58M_{3,t-1}^{(3)} + 35,78M_{4,t-1}^{(3)} + N_t^{(3)}. \end{aligned} \quad (4.28)$$

Dari hasil pemodelan level satu pada persamaan (4.26)–(4.28) diperoleh residual $N_t^{(i)}$. Residual ini akan digunakan sebagai input dalam pemodelan level

dua, yaitu untuk model GSTAR yang nantinya akan didapatkan parameter antar lokasi (spasial). *Series* residual $N_t^{(i)}$ ditunjukkan pada Gambar 4.14.



Gambar 4. 14 Plot *Time Series* Residual Simulasi Skenario 2, (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3.

Terlihat pada Gambar 4.14 residual dari ketiga lokasi menunjukkan kondisi yang stasioner, artinya berada disekitar $\mu = 0$. Pemeriksaan stasioneritas pada **tahap dua** juga dapat dilihat melalui skematik MCCF pada Gambar 4.15. Terlihat bahwa model VAR menunjukkan kondisi yang stasioner.

Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
zresid11	+++	+++	+++	+++	+++
zresid21	+++	+++	+++	+++	+++
zresid31	+++	+++	+++	+++	+++

Gambar 4. 15 Representasi Skematik MCCF Skenario 2 di Ketiga Lokasi.

Tahap tiga, adalah melakukan pemodelan VAR untuk memodelkan hubungan antar lokasi. Pertama tama dilakukan pemeriksaan orde AR melalui skematik MPCCF dan nilai AIC minimum. Hasil identifikasi tahap tiga, terlihat pada Tabel 4.3 dan Gambar 4.16.

Tabel 4. 3 Nilai AIC Residual TSR Skenario 2

Lag	MA(0)	MA(1)	MA(2)	MA(3)	MA(4)	MA(5)
AR(0)	2,1206	2,0850	1,8526	1,8127	1,7712	1,7750
AR(1)	1,8975	1,8608	1,7557	1,7644	1,7514	1,7566
AR(2)	1,7011	1,6954	1,7313	1,7513	1,7387	1,7649
AR(3)	1,7204	1,7101	1,7561	1,7730	1,7713	1,7906
AR(4)	1,7277	1,7240	1,7459	1,7695	1,7930	1,8078
AR(5)	1,7603	1,7542	1,7792	1,7805	1,8186	1,8296

Nilai AIC pada Tabel 4.3 menunjukkan bahwa model yang terbentuk adalah VAR (2). Hal ini ditunjukkan dengan nilai minimum terdapat pada orde AR (2) dan MA (0). Pemeriksaan orde waktu dari model VAR dapat pula dilakukan dengan melihat skematik MPCCF seperti pada Gambar 4.16.

Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
zresid11	+.+	+.+
zresid21	++.	++.
zresid31	+++	+++

Gambar 4. 16 Representasi Skematik MPCCF Skenario 2.

Skematik MPCCF menunjukkan bahwa tanda positif (+) yang muncul pada ketiga lokasi hanya pada lag ke-1 dan ke-2, artinya data simulasi dari ketiga lokasi adalah benar pada VAR (2).

Hasil estimasi parameter model VAR (2) pada level dua seperti ditunjukkan pada Lampiran 2 Tabel C. Maka model VAR (2) yang diperoleh adalah

i. Lokasi satu

$$N_t^{(1)*} = 0,035N_{t-1}^{(1)} + 0,124N_{t-1}^{(2)} + 0,168N_{t-1}^{(3)} + 0,088N_{t-2}^{(1)} - 0,158N_{t-2}^{(2)} + 0,472N_{t-2}^{(3)} + a_t^{(1)} \quad (4.29)$$

ii. Lokasi dua

$$N_t^{(2)*} = -0,102N_{t-1}^{(1)} + 0,229N_{t-1}^{(2)} + 0,183N_{t-1}^{(3)} - 0,155N_{t-2}^{(1)} + 0,082N_{t-2}^{(2)} + 0,458N_{t-2}^{(3)} + a_t^{(2)} \quad (4.30)$$

iii. Lokasi tiga

$$N_t^{(3)*} = -0,009N_{t-1}^{(1)} + 0,106N_{t-1}^{(2)} + 0,201N_{t-1}^{(3)} - 0,084N_{t-2}^{(1)} - 0,157N_{t-2}^{(2)} + 0,6N_{t-2}^{(3)} + a_t^{(3)} \quad (4.31)$$

Tahap empat adalah menentukan bobot spasial yang diberikan pada masing-masing lokasi. Metode pembobotan spasial yang digunakan pada simulasi

ini dibatasi pada bobot seragam. Namun nantinya pada kajian terapan dimungkinkan menggunakan bobot lain yang terbaik, salah satunya Normalisasi Inferensi Korelasi Silang Parsial. Bobot ini diperoleh berdasarkan tinggi rendahnya nilai korelasi silang parsial antar lokasi. Hasil perhitungan parsial korelasi silang antar lokasi pada lag waktu ke-1, atau $r_{ij}(1)$ dengan $i, j = 1, 2, 3$ dan $i \neq j$ dapat dilihat pada Tabel 4.4. Proses inferensia statistik dilakukan dengan menggunakan taksiran interval 95%.

Tabel 4. 4 Taksiran NIKSP Lag-1 Skenario 2.

Parameter	Estimasi	Taksiran interval 95%		Keputusan
		Batas bawah	Batas atas	
$P_{12}(1)$	0,0465	-0,0535	0,1466	Tidak Valid
$P_{13}(1)$	0,1582	0,0581	0,2582	Valid
$P_{21}(1)$	0,1212	0,0212	0,2213	Valid
$P_{23}(1)$	0,0775	-0,0225	0,1775	Tidak Valid
$P_{31}(1)$	0,1535	0,0535	0,2536	Valid
$P_{32}(1)$	0,1325	0,0324	0,2325	Valid

Berdasarkan perhitungan dari hasil besaran korelasi silang antar lokasi pada lag ke-1, proses inferensia statistik pada Tabel 4.4 menunjukkan bahwa beberapa taksiran interval menghasilkan batas yang sama (tanda hubungan), sehingga memberikan keputusan valid dan sebanding, artinya ada perbedaan untuk pemberian bobot antar lokasi. Metode pembobotan yang sesuai pada skenario ini adalah selain bobot seragam. Hasil perhitungan korelasi silang parsial antar lokasi pada lag waktu ke-2, atau $r_{ij}(2)$ dengan $i, j = 1, 2, 3$ dan $i \neq j$ dapat dilihat pada Tabel 4.5.

Tabel 4. 5 Taksiran NIKSP Lag-2 Skenario 2.

Parameter	Estimasi	Taksiran interval 95%		Keputusan
		Batas bawah	Batas atas	
$P_{12}(1)$	-0,0011	-0,1011	0,0989	Tidak Valid
$P_{13}(1)$	0,0498	-0,0502	0,1498	Tidak Valid
$P_{21}(1)$	0,0393	-0,0607	0,1393	Tidak Valid
$P_{23}(1)$	-0,0431	-0,1431	0,0570	Tidak Valid
$P_{31}(1)$	0,1243	0,0243	0,2244	Valid
$P_{32}(1)$	0,1170	0,0170	0,2170	Valid

Sedangkan pada lag ke-2, terlihat bahwa beberapa taksiran interval juga menghasilkan batas yang sama (tanda hubungan), sehingga memberikan

keputusan valid dan sebanding, artinya ada perbedaan untuk pemberian bobot antar lokasi. Metode pembobotan yang sesuai pada skenario ini adalah selain bobot seragam. **Tahap lima** adalah melakukan estimasi parameter di level dua, model GSTARX. Pada tahap ini akan digunakan metode estimasi OLS dan GLS. Hasil estimasi parameter model GSTARX (2₁) pada level dua seperti ditunjukkan pada Lampiran 2 Tabel F. Dari tabel terlihat bahwa terdapat efisiensi GLS, hal ini sesuai desain simulasi yang diberikan. Secara umum, untuk skenario residual saling berkorelasi antar lokasi metode estimasi OLS dan GLS akan menghasilkan nilai standar *error* parameter yang berbeda. Hasil estimasi parameter model GSTAR (2₁) untuk level dua dapat dituliskan sebagai berikut.

a. GSTAR(2₁)-OLS

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,054 & 0,136 & 0,136 \\ 0,009 & 0,282 & 0,009 \\ 0,050 & 0,050 & 0,192 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,238 & 0,068 & 0,068 \\ 0,091 & 0,167 & 0,091 \\ -0,122 & -0,122 & 0,608 \end{bmatrix} \begin{bmatrix} N_{t-2}^{(1)} \\ N_{t-2}^{(2)} \\ N_{t-2}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix} \quad (4.32)$$

i. Lokasi satu

$$N_t^{(1)*} = 0,054N_{t-1}^{(1)} + 0,136N_{t-1}^{(2)} + 0,136N_{t-1}^{(3)} + 0,238N_{t-2}^{(1)} + 0,068N_{t-2}^{(2)} + 0,068N_{t-2}^{(3)} + a_t^{(1)} \quad (4.33)$$

ii. Lokasi dua

$$N_t^{(2)*} = 0,009N_{t-1}^{(1)} + 0,282N_{t-1}^{(2)} + 0,009N_{t-1}^{(3)} + 0,091N_{t-2}^{(1)} + 0,167N_{t-2}^{(2)} + 0,091N_{t-2}^{(3)} + a_t^{(2)} \quad (4.34)$$

iii. Lokasi tiga

$$N_t^{(3)*} = 0,05N_{t-1}^{(1)} + 0,05N_{t-1}^{(2)} + 0,192N_{t-1}^{(3)} - 0,122N_{t-2}^{(1)} - 0,122N_{t-2}^{(2)} + 0,608N_{t-2}^{(3)} + a_t^{(3)} \quad (4.35)$$

Secara lengkap model GSTARX (2₁)-OLS untuk level satu dan dua dapat dituliskan

$$\begin{aligned}
\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} &= \begin{bmatrix} 0,054 & 0,136 & 0,136 \\ 0,009 & 0,282 & 0,009 \\ 0,050 & 0,050 & 0,192 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,238 & 0,068 & 0,068 \\ 0,091 & 0,167 & 0,091 \\ -0,122 & -0,122 & 0,608 \end{bmatrix} \begin{bmatrix} N_{t-2}^{(1)} \\ N_{t-2}^{(2)} \\ N_{t-2}^{(3)} \end{bmatrix} + \\
&\begin{bmatrix} 0,21 & 0 & 0 \\ 0 & 0,23 & 0 \\ 0 & 0 & 0,24 \end{bmatrix} \begin{bmatrix} T_t^{(1)} \\ T_t^{(2)} \\ T_t^{(3)} \end{bmatrix} + \begin{bmatrix} 23,09 & 0 & 0 \\ 0 & 25,85 & 0 \\ 0 & 0 & 17,99 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 18,07 & 0 & 0 \\ 0 & 21,91 & 0 \\ 0 & 0 & 13,01 \end{bmatrix} \begin{bmatrix} S_{12,t}^{(1)} \\ S_{12,t}^{(2)} \\ S_{12,t}^{(3)} \end{bmatrix} + \begin{bmatrix} 31,65 & 0 & 0 \\ 0 & 59,11 & 0 \\ 0 & 0 & 36,79 \end{bmatrix} \begin{bmatrix} M_{1,t}^{(1)} \\ M_{1,t}^{(2)} \\ M_{1,t}^{(3)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 49,23 & 0 & 0 \\ 0 & 56,99 & 0 \\ 0 & 0 & 51,11 \end{bmatrix} \begin{bmatrix} M_{4,t}^{(1)} \\ M_{4,t}^{(2)} \\ M_{4,t}^{(3)} \end{bmatrix} + \begin{bmatrix} 49,85 & 0 & 0 \\ 0 & 59,11 & 0 \\ 0 & 0 & 48,64 \end{bmatrix} \begin{bmatrix} M_{1,t-1}^{(1)} \\ M_{1,t-1}^{(2)} \\ M_{1,t-1}^{(3)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 32,66 & 0 & 0 \\ 0 & 35,12 & 0 \\ 0 & 0 & 35,78 \end{bmatrix} \begin{bmatrix} M_{4,t-1}^{(1)} \\ M_{4,t-1}^{(2)} \\ M_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}
\end{aligned}$$

b. GSTAR(1₁)-GLS

$$\begin{bmatrix} N_t^{(1)} \\ N_t^{(2)} \\ N_t^{(3)} \end{bmatrix} = \begin{bmatrix} 0,134 & 0,091 & 0,091 \\ 0,033 & 0,229 & 0,033 \\ 0,090 & 0,090 & 0,108 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,236 & 0,069 & 0,069 \\ 0,027 & 0,299 & 0,027 \\ 0,048 & 0,048 & 0,238 \end{bmatrix} \begin{bmatrix} N_{t-2}^{(1)} \\ N_{t-2}^{(2)} \\ N_{t-2}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix} \quad (4.36)$$

i. Lokasi satu

$$N_t^{(1)*} = 0,134N_{t-1}^{(1)} + 0,091N_{t-1}^{(2)} + 0,091N_{t-1}^{(3)} + 0,236N_{t-2}^{(1)} - 0,069N_{t-2}^{(2)} + 0,069N_{t-2}^{(3)} + a_t^{(1)} \quad (4.37)$$

ii. Lokasi dua

$$N_t^{(2)*} = 0,033N_{t-1}^{(1)} + 0,229N_{t-1}^{(2)} + 0,033N_{t-1}^{(3)} + 0,027N_{t-2}^{(1)} + 0,299N_{t-2}^{(2)} + 0,027N_{t-2}^{(3)} + a_t^{(2)} \quad (4.38)$$


iii. Lokasi tiga

$$N_t^{(3)*} = 0,09N_{t-1}^{(1)} + 0,09N_{t-1}^{(2)} + 0,108N_{t-1}^{(3)} + 0,048N_{t-2}^{(1)} + 0,048N_{t-2}^{(2)} + 0,238N_{t-2}^{(3)} + a_t^{(3)} \quad (4.39)$$

Sehingga, secara lengkap model GSTARX(1₁)-GLS untuk level satu dan dua dapat dituliskan

$$\begin{aligned}
\begin{bmatrix} Y_t^{(1)} \\ Y_t^{(2)} \\ Y_t^{(3)} \end{bmatrix} &= \begin{bmatrix} 0,134 & 0,091 & 0,091 \\ 0,033 & 0,229 & 0,033 \\ 0,090 & 0,090 & 0,108 \end{bmatrix} \begin{bmatrix} N_{t-1}^{(1)} \\ N_{t-1}^{(2)} \\ N_{t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} 0,236 & 0,069 & 0,069 \\ 0,027 & 0,299 & 0,027 \\ 0,048 & 0,048 & 0,238 \end{bmatrix} \begin{bmatrix} N_{t-2}^{(1)} \\ N_{t-2}^{(2)} \\ N_{t-2}^{(3)} \end{bmatrix} + \\
&\begin{bmatrix} 0,21 & 0 & 0 \\ 0 & 0,23 & 0 \\ 0 & 0 & 0,24 \end{bmatrix} \begin{bmatrix} T_t^{(1)} \\ T_t^{(2)} \\ T_t^{(3)} \end{bmatrix} + \begin{bmatrix} 23,09 & 0 & 0 \\ 0 & 25,85 & 0 \\ 0 & 0 & 17,99 \end{bmatrix} \begin{bmatrix} S_{1,t}^{(1)} \\ S_{1,t}^{(2)} \\ S_{1,t}^{(3)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 18,07 & 0 & 0 \\ 0 & 21,91 & 0 \\ 0 & 0 & 13,01 \end{bmatrix} \begin{bmatrix} S_{12,t}^{(1)} \\ S_{12,t}^{(2)} \\ S_{12,t}^{(3)} \end{bmatrix} + \begin{bmatrix} 31,65 & 0 & 0 \\ 0 & 59,11 & 0 \\ 0 & 0 & 36,79 \end{bmatrix} \begin{bmatrix} M_{1,t}^{(1)} \\ M_{1,t}^{(2)} \\ M_{1,t}^{(3)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 49,23 & 0 & 0 \\ 0 & 56,99 & 0 \\ 0 & 0 & 51,11 \end{bmatrix} \begin{bmatrix} M_{4,t}^{(1)} \\ M_{4,t}^{(2)} \\ M_{4,t}^{(3)} \end{bmatrix} + \begin{bmatrix} 49,85 & 0 & 0 \\ 0 & 59,11 & 0 \\ 0 & 0 & 48,64 \end{bmatrix} \begin{bmatrix} M_{1,t-1}^{(1)} \\ M_{1,t-1}^{(2)} \\ M_{1,t-1}^{(3)} \end{bmatrix} + \dots + \\
&\begin{bmatrix} 32,66 & 0 & 0 \\ 0 & 35,12 & 0 \\ 0 & 0 & 35,78 \end{bmatrix} \begin{bmatrix} M_{4,t-1}^{(1)} \\ M_{4,t-1}^{(2)} \\ M_{4,t-1}^{(3)} \end{bmatrix} + \begin{bmatrix} a_t^{(1)} \\ a_t^{(2)} \\ a_t^{(3)} \end{bmatrix}
\end{aligned}$$

Tahap keenam, adalah melakukan pemodelan non linier. Residual yang diperoleh dari tahap satu dapat disajikan dalam matriks plot pada Gambar 4.17. Matriks plot menunjukkan residual tahap pertama mengandung pola nonlinier. Maka selanjutnya dilakukan pemodelan non linier dengan VARX-SVR dan GSTARX-SVR.



Gambar 4. 17 Matriks Plot Residual Simulasi Skenario 2

Kombinasi nilai parameter yang digunakan sama seperti pada skenario 1. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai RMSE terkecil seperti pada Lampiran 2 Tabel D dan G.

Tabel D menunjukkan nilai MAPEp model VARX-SVR pada data *out sample* yang paling kecil untuk lokasi 1 adalah 2,979492, yaitu dengan nilai epsilon 0,00006, nilai *cost* sebesar 353,7 dan nilai sigma sebesar 0,08. Pada lokasi 2, MAPE terkecil sebesar 2,414975 dengan nilai epsilon 0,00007, *cost* sebesar 350,8 dan sigma sebesar 0,10. Sedangkan untuk lokasi 3, MAPE terkecil sebesar 2,392226, dengan nilai epsilon 0,00009, *cost* sebesar 350,9 dan sigma sebesar 0,09. Sehingga didapat persamaan VARX-SVR sebagai berikut,

i. Lokasi Satu

$$\begin{aligned}\hat{Y}_t^{(1)} &= \sum_{i=1}^{382} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= -100,63 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 293,08 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &\quad -206,15 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 117,21 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{380} - \mathbf{x}\|^2\right) + \\ &\quad 193,23 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + 212,387 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) - 0,198\end{aligned}\quad (4.40)$$

ii. Lokasi Dua

$$\begin{aligned}\hat{Y}_t^{(2)} &= \sum_{i=1}^{382} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= -67,68 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 271,188 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &\quad -286,09 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 259,35 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{380} - \mathbf{x}\|^2\right) + \\ &\quad -95,21 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + 226,76 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 0,14\end{aligned}\quad (4.41)$$

iii. Lokasi Tiga

$$\begin{aligned}\hat{Y}_t^{(3)} &= \sum_{i=1}^{382} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= -39,03 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 323 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &\quad -222,8 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 216,32 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{380} - \mathbf{x}\|^2\right) + \\ &\quad -54,65 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + 221,54 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 0,69\end{aligned}\quad (4.42)$$

Tabel G menunjukkan nilai MAPEp model GSTARX-SVR pada data *out sample* yang paling kecil untuk lokasi 1 adalah 2,929759, yaitu dengan nilai epsilon 0,00006, nilai *cost* sebesar 350 dan nilai sigma sebesar 0,05. Pada lokasi 2, MAPE terkecil sebesar 2,408432 dengan nilai epsilon 0,00008, *cost* sebesar

354,2 dan sigma sebesar 0,05. Sedangkan untuk lokasi 3, MAPE terkecil sebesar 2,303094, dengan nilai epsilon 0,00006, *cost* sebesar 350 dan sigma sebesar 0,05.

Sehingga didapat persamaan GSTARX-SVR sebagai berikut,

i. Lokasi Satu

$$\begin{aligned}
 \hat{Y}_t^{(1)} &= \sum_{i=1}^{382} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= -350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &\quad -350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{380} - \mathbf{x}\|^2\right) + \\
 &\quad 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 1,024
 \end{aligned} \tag{4.43}$$


ii. Lokasi Dua

$$\begin{aligned}
 \hat{Y}_t^{(2)} &= \sum_{i=1}^{382} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= -354,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 354,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &\quad -354,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 354,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{380} - \mathbf{x}\|^2\right) + \\
 &\quad 354,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) + 354,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 0,74
 \end{aligned} \tag{4.44}$$

iii. Lokasi Tiga

$$\begin{aligned}
 \hat{Y}_t^{(3)} &= \sum_{i=1}^{382} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= 2,48 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &\quad -350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{380} - \mathbf{x}\|^2\right) + \\
 &\quad 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{381} - \mathbf{x}\|^2\right) - 130,87 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{382} - \mathbf{x}\|^2\right) + 0,777
 \end{aligned} \tag{4.45}$$

Maka didapatkan hasil peramalan pada data *training (in sample)* dan *testing (out sample)* seperti ditampilkan pada Gambar 4.18. Garis hitam menunjukkan nilai yang sebenarnya, garis biru menunjukkan nilai hasil ramalan data *in-sample*. Sedangkan nilai merah menunjukkan nilai hasil ramalan data *out-sample*. Terlihat bahwa garis biru cenderung mengikuti pola dari garis hitam, begitu pula dengan garis merah. Hal ini menunjukkan model VARX-SVR dan GSTARX-SVR dengan parameter tersebut dapat memodelkan dengan baik.




Gambar 4. 18 Time Series Hasil Peramalan Model VARX-SVR (1) dan GSTARX-SVR (2) di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3.

4.1.3 Pemilihan Model Terbaik Data Simulasi


Setelah dilakukan pemodelan data simulasi dengan menggunakan model VARX, *Hybrid* VARX-SVR, GSTARX dan *Hybrid* GSTARX-SVR, maka didapatkan hasil ramalan untuk data *training* (*in-sample*) dan *testing* (*out-sample*). Ramalan yang dilakukan adalah dengan langkah *k-step*. Selanjutnya, dapat dihitung nilai RMSE untuk masing-masing model seperti pada Lampiran 1 Tabel K.

Model terbaik adalah model dengan nilai RMSE *out-sample* terkecil, hal ini terkait dengan akurasi peramalan dari model yang telah dibangun terhadap model yang divalidasi. Nilai RMSE masing-masing model disajikan pada boxplot pada Gambar 4.19. Pada data *testing* simulasi skenario 1, model terbaik adalah model VARX, sedangkan di data *training* model nilai RMSE terkecil berturut-turut model VARX-SVR, GSTARX-SVR, VARX dan GSTARX. Pada data *testing* simulasi skenario 2 nilai RMSE terkecil berturut-turut model VARX-SVR, GSTARX-SVR, VARX dan GSTARX begitu pula pada data *training*. Model *hybrid* cenderung baik dalam data *training* namun *overfitting* pada data *testing*.



Gambar 4. 19 Nilai RMSE Keempat Model Residual Linier (kiri) dan Residual Non Linier (kanan) di (a) Data *Training* (*in sample*), (b) Data *Testing* (*out sample*)

Diantara sesama pemodelan linier, model VARX terlihat memiliki nilai RMSE yang lebih kecil dibandingkan model GSTARX. Pola ini diikuti oleh pemodelan non liniernya yaitu *Hybrid* VARX-SVR yang memiliki nilai RMSE lebih kecil dibandingkan *Hybrid* GSTARX-SVR. Namun baik pada simulasi skenario satu maupun skenario dua, model *hybrid* memberikan kinerja yang lebih baik dibandingkan model linier.



Gambar 4. 20 Peningkatan Kebaikan Model Non Linier dari Model Linier untuk Simulasi (a) Residual Linier dan (b) Residual Non Linier

Model *hybrid* dengan SVR yang merupakan model non linier terlihat bekerja sangat baik pada simulasi skenario dua yang merupakan simulasi dengan


residual non linier. Artinya, model *hybrid* VARX-SVR dan GSTARX-SVR dapat menangkap pola non linier dari data. Pada data *training*, model *hybrid* VARX-SVR mampu menurunkan tingkat kesalahan ramalan VARX hingga 71%. *Hybrid* GSTARX-SVR menurunkan tingkat kesalahan ramalan GSTAR sebesar 50%. Pada data *testing*, *hybrid* GSTARX-SVR mampu mengurangi kesalahan ramalan GSTARX sebesar 10%. Sedangkan model *hybrid* VARX-SVR mengurangi kesalahan ramalan sebesar 8% dari model VARX.

Sedangkan pada simulasi skenario satu dengan residual linier, model *hybrid* VARX-SVR tidak lebih baik dibandingkan model VARX pada data *testing*. Tidak banyak menurunkan kesalahan ramalan pada data *training* pula, hanya 3%. Berbeda dengan model *hybrid* VARX-SVR, Model *hybrid* GSTARX-SVR lebih baik daripada model GSTARX-SVR dalam memodelkan data *testing* hingga mampu menurunkan tingkat kesalahan ramalan sebesar 35% pada data *testing*, walaupun hanya 1% di data *training*.

4.1.4 Peramalan *Out Sample* Model Dua Level

Pada bagian ini, perhitungan nilai ramalan model GSTAR dibatasi hanya dengan metode estimasi GLS. Ramalan *out sample* untuk data simulasi dengan residual bersifat linier dapat dilihat pada Lampiran 1 Tabel J. Sedangkan ramalan *out sample* untuk data simulasi dengan residual bersifat non linier dapat dilihat pada Lampiran 1 Tabel I.

Gambar 4.21 merupakan plot ramalan *out sample* untuk keempat model di ketiga lokasi. Terlihat bahwa baik pada simulasi residual linier maupun non linier, model VARX memiliki nilai RMSE terkecil hampir di semua lokasi. Sedangkan RMSE terbesar terbanyak ada pada model GSTARX, khususnya pada simulasi residual linier. Sedangkan pada simulasi residual non linier, model VARX-SVR memiliki nilai RMSE yang terbesar di dua lokasi.



Gambar 4. 21 Nilai Ramalan Keempat Model Residual Linier (kiri) Dan Residual Non Linier (kanan) di (a) Lokasi 1, (b) Lokasi 2 dan (c) Lokasi 3

Peramalan model *hybrid* didapatkan dari penjumlahan ramalan pada tahap satu dan tahap dua, seperti berikut,

$$Z_t^{(1)} = Y_t^{(1)*} + N_t^{(1)}$$

$$Z_t^{(2)} = Y_t^{(2)*} + N_t^{(2)}$$

$$Z_t^{(3)} = Y_t^{(3)*} + N_t^{(3)}$$

Model VARX lokasi satu pada simulasi skenario satu didapatkan dari penjumlahan pers. 4.5 dan pers. 4.9. Dengan

$$\begin{aligned}
Y_t^{(1)*} = & 0,21T_t^{(1)} + 22,02S_{1,t}^{(1)} + 23,97S_{2,t}^{(1)} + 27,01S_{3,t}^{(1)} + 24,12S_{4,t}^{(1)} + \\
& 22,1S_{5,t}^{(1)} + 17,18S_{6,t}^{(1)} + 13,52S_{7,t}^{(1)} + 10,26S_{8,t}^{(1)} + 6,24S_{9,t}^{(1)} + \\
& 10,03S_{10,t}^{(1)} + 13,20S_{11,t}^{(1)} + 17,13S_{12,t}^{(1)} + 32,41M_{1,t}^{(1)} + 43,57M_{2,t}^{(1)} + \\
& 46,44M_{3,t}^{(1)} + 48,61M_{4,t}^{(1)} + 49,91M_{1,t-1}^{(1)} + 46,39M_{2,t-1}^{(1)} + \\
& 38,72M_{3,t-1}^{(1)} + 32,34M_{4,t-1}^{(1)} + N_t^{(1)}.
\end{aligned}$$

$$N_t^{(1)*} = 0,2781N_{t-1}^{(1)} + 0,2858N_{t-1}^{(2)} + 0,3784N_{t-1}^{(3)} + a_t^{(1)}$$

Begitupula untuk lokasi dua dan lokasi tiga yang didapatkan dari penjumlahan pers. 4.6-4.7 dan 4.10-4.11.

Peramalan GSTARX pada simulasi skenario satu didapatkan dari penjumlahan pers. 4.5 dan 4.17 untuk lokasi satu, pers. 4.6 dan 4.18 untuk lokasi dua serta penjumlahan pers. 4.7 dan 4.19 untuk lokasi tiga. Peramalan *hybrid* VARX-SVR pada simulasi skenario satu didapatkan dari penjumlahan pers. 4.5 dan 4.20 untuk lokasi satu, pers. 4.6 dan 4.21 untuk lokasi dua serta penjumlahan pers. 4.7 dan 4.22 untuk lokasi tiga. Peramalan *hybrid* GSTARX-SVR pada simulasi skenario satu didapatkan dari penjumlahan pers. 4.5 dan 4.23 untuk lokasi satu, pers. 4.6 dan 4.24 untuk lokasi dua serta penjumlahan pers. 4.7 dan 4.25 untuk lokasi tiga.


Peramalan VARX pada simulasi skenario dua didapatkan dari penjumlahan pers. 4.26 dan 4.29 untuk lokasi satu, pers. 4.27 dan 4.30 untuk lokasi dua serta penjumlahan pers. 4.28 dan 4.31 untuk lokasi tiga. Peramalan GSTARX pada simulasi skenario dua didapatkan dari penjumlahan pers. 4.26 dan 4.37 untuk lokasi satu, pers. 4.27 dan 4.38 untuk lokasi dua serta penjumlahan pers. 4.28 dan 4.39 untuk lokasi tiga. Peramalan *hybrid* VARX-SVR pada simulasi skenario satu didapatkan dari penjumlahan pers. 4.26 dan 4.40 untuk lokasi satu, pers. 4.27 dan 4.41 untuk lokasi dua serta penjumlahan pers. 4.28 dan 4.42 untuk lokasi tiga. Peramalan *hybrid* GSTARX-SVR pada simulasi skenario satu didapatkan dari penjumlahan pers. 4.26 dan 4.43 untuk lokasi satu, pers. 4.27 dan 4.44 untuk lokasi dua serta penjumlahan pers. 4.28 dan 4.45 untuk lokasi tiga.

4.2 Pemodelan Data Terapan

Pada bagian ini, sebelum dilakukan pemodelan data *inflow* dan *outflow*, langkah awal yang dilakukan adalah tahap eksplorasi data, dengan menggunakan metode statistika deskriptif. Secara lengkap berikut hasil dan pembahasan.

4.2.1 Statistika Deskriptif

Tahap identifikasi pertama dalam pemodelan *time series* adalah dengan melihat pola data melalui plot *time series* dan statistika deskriptif. Kedua hal tersebut akan diaplikasikan pada data *inflow* dan *outflow* untuk ketiga lokasi KPW II BI (Jawa Barat), yang ditampilkan pada Gambar 4.22



Gambar 4. 22 Plot *Time series* *Inflow* dan *Outflow* di (a) Bandung, (b) Tasikmalaya, (c) Cirebon.

Pada Gambar 4.22 terlihat bahwa adanya kenaikan *outflow* yang signifikan pada waktu-waktu tertentu. Kenaikan tersebut terjadi diduga akibat adanya lebaran Idul Fitri, kemudian yang berdampak pada meningkatnya *outflow* dibandingkan dengan bulan-bulan lainnya. Pada bulan Juli tahun 2014 (data *out-sample*) terjadi peningkatan *outflow* sangat signifikan di setiap KBI saat terjadinya lebaran Idul Fitri, *outflow* pada bulan tersebut melonjak hingga diatas 7 M. Secara umum, perubahan tinggi atau rendahnya data *outflow* pada ketiga lokasi yaitu ketika *outflow* di suatu KBI meningkat, maka pada waktu yang sama pula *outflow* di KBI lainnya juga cenderung meningkat. Begitupula untuk data *inflow*. Hanya saja peningkatan *inflow* terjadi pada bulan setelah adanya lebaran Idul Fitri.

Tabel 4. 6 Statistika Deskriptif Data *Inflow* dan *Outflow* (dalam milyar).

KBI	<i>Outflow</i>				<i>Inflow</i>			
	<i>Mean</i>	<i>St. Dev</i>	<i>Min</i>	<i>Max</i>	<i>Mean</i>	<i>St. Dev</i>	<i>Min</i>	<i>Max</i>
Bandung	1235	1096	23	7379	2132	1570	165	9575
Tasikmalaya	170	175	2	1225	467	241	66	1399
Cirebon	299	254	2	1612	841	387	211	2344

Dari Tabel 4.6 menunjukkan bahwa KBI yang memiliki rata-rata *outflow* tertinggi adalah KBI Bandung, yaitu sebanyak 1235 M per bulan dengan *outflow* tertinggi dan terendah per bulan tercatat 23 M dan 7379 M. Selain itu, tingkat keragaman data pada ketiga KBI cenderung tinggi, dengan tingkat keragaman tertinggi terdapat pada KBI Bandung, yaitu sebesar 1096. Hal yang sama juga terjadi pada data *inflow*. Analisa statistika deskriptif data *outflow* perbulan dalam bentuk tabel untuk masing-masing KBI ditampilkan pada Lampiran 3 Tabel A.

Untuk melakukan pemodelan non linier, sebelumnya perlu dilakukan uji non linieritas. Uji yang digunakan adalah uji terasvirta, uji ini dipilih karena memiliki power yang lebih baik dibandingkan uji yang lain, seperti *white test* atau *reset test*. Pengujian ini dilakukan untuk mengetahui apakah data memiliki unsur *neglected nonlinearity*. Hipotesis awal yang digunakan adalah data tidak memenuhi unsur *neglected nonlinearity*. Hasil pengujian yang telah dilakukan ditampilkan pada Tabel 4.7.

Tabel 4. 7 Uji *Neglected Nonlinearity* pada Data Terhadap Periode Waktu t

Data	Lokasi	df	χ^2	P-Value
<i>Outflow</i>	KBI Bandung	2	31,2081	0,0000
	KBI Tasikmalaya	2	63,3463	0,0000
	KBI Cirebon	2	33,5406	0,0000
<i>Inflow</i>	KBI Bandung	2	61,0345	0,0000
	KBI Tasikmalaya	2	40,9906	0,0000
	KBI Cirebon	2	56,0695	0,0000

Berdasarkan nilai p yang lebih kecil dari $\alpha=0,05$, maka keputusan yang didapatkan dari hasil pengujian pada seluruh data adalah menolak hipotesis nol, artinya data memiliki unsur *neglected nonlinearity*.

4.2.2 Pemodelan Data *Outflow* Bank Indonesia

Sama seperti pada studi simulasi, penerapan pada data riil untuk estimasi parameter model dilakukan dengan dua level dengan tahapan yang sama.

a. Estimasi Parameter Model Level 1

Pada tahap ini dilakukan estimasi level satu dengan regresi *time series*, sehingga diperoleh residual $N_t^{(i)}$, dengan $i = 1, 2, 3$. Hasil dari estimasi parameter level satu diberikan dengan

i. KBI Bandung

$$\begin{aligned}
 Y_t^{(1)*} = & 19,68T_t^{(1)} - 1394,99D_{1,t}^{(1)} - 3263,84D_{2,t}^{(1)} + 20,04TD_{2,t}^{(1)} + 295,21S_{3,t}^{(1)} + \\
 & 351,61S_{4,t}^{(1)} + 315,21S_{5,t}^{(1)} + 609,57S_{6,t}^{(1)} + 687,52S_{7,t}^{(1)} + 314,56S_{8,t}^{(1)} + \\
 & 1239,59S_{12,t}^{(1)} + 1104,46M_{2,t}^{(1)} + 2490,87M_{3,t}^{(1)} + 2404,38M_{4,t}^{(1)} + \\
 & 2205,91M_{1,t-1}^{(1)} + 1252,35M_{2,t-1}^{(1)} + N_t^{(1)}.
 \end{aligned} \tag{4.46}$$

Outflow mengalami efek variasi kalender Lebaran di KBI Bandung pada bulan yang terdapat Hari Raya Idul Fitri baik pada minggu ke 1,2,3 atau 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

ii. KBI Tasikmalaya

$$\begin{aligned}
 Y_t^{(2)*} = & 4,39T_t^{(2)} - 318,47D_{1,t}^{(2)} - 809,33D_{2,t}^{(2)} + 4,22TD_{2,t}^{(2)} + 71,73S_{6,t}^{(2)} + \\
 & 70,5S_{7,t}^{(2)} + 141,92S_{12,t}^{(2)} + 166,78M_{2,t}^{(2)} + 247,12M_{3,t}^{(2)} + 269,73M_{4,t}^{(2)} + \\
 & 309,83M_{1,t-1}^{(2)} + 136,25M_{2,t-1}^{(2)} + N_t^{(2)}.
 \end{aligned} \tag{4.47}$$


Efek variasi kalender Lebaran di KBI Tasikmalaya terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, ke-3 atau ke-4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

iii. KBI Cirebon

$$Y_t^{(3)*} = -578,59D_{1,t}^{(3)} - 995,16D_{2,t}^{(3)} + 6,09TD_{1,t}^{(3)} + 9,95TD_{2,t}^{(3)} + 129,15S_{1,t}^{(3)} + 130,19S_{2,t}^{(3)} + 207,52S_{3,t}^{(3)} + 294,81S_{4,t}^{(3)} + 207,44S_{5,t}^{(3)} + 357,31S_{6,t}^{(3)} + 298,43S_{7,t}^{(3)} + 217,48S_{8,t}^{(3)} + 148,07S_{9,t}^{(3)} + 180,88S_{10,t}^{(3)} + 160,03S_{11,t}^{(3)} + 353,99S_{12,t}^{(3)} + 354,98M_{2,t}^{(3)} + 579,64M_{3,t}^{(3)} + 483,53M_{4,t}^{(3)} + 672,69M_{1,t-1}^{(3)} + 309,84M_{2,t-1}^{(3)} + N_t^{(3)}. \quad (4.48)$$

Outflow mengalami efek variasi kalender Lebaran di KBI Cirebon pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, 3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

Pada tahapan selanjutnya, residual level satu menjadi variabel respon di level 2. Residual tahap satu dapat disajikan dalam matriks plot sebagai berikut,




Gambar 4. 23 Matriks Plot Residual Data *Outflow*

Matriks plot pada Gambar 4.23 menunjukkan residual tahap pertama mengandung pola non linier. Sehingga dapat dilakukan pemodelan non linier dengan SVR.

b. Identifikasi Orde Model Level 2

Bentuk model $N_t^{(i)}$ pada masing-masing lokasi ditunjukkan pada Gambar 4.24



Gambar 4. 24 Plot *Time Series Residual Outflow*, (a) Bandung, (b) Tasikmalaya dan (c) Cirebon.

Dari model $N_t^{(i)}$ yang telah didapatkan, selanjutnya dilakukan pemeriksaan stasioneritas dan juga penentuan orde AR. Skematik MCCF pada Gambar 4.25 menunjukkan bahwa data telah stasioner. Hal ini terlihat dari banyaknya tanda (·) yang muncul.

Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
zresid11	+++	+.+	+.+	+++
zresid21	+++	+.+	+++
zresid31	+++

Gambar 4. 25 Representasi Skematik MCCF Model $N_t^{(i)}$ Data *Outflow*.

Setelah data stasioner, maka dilakukan perhitungan dan analisis bentuk dari MCCF dan MPCCF. Kedua besaran ini digunakan sebagai dasar untuk penentuan orde model VAR, khususnya pada plot MPCCF, yang hasilnya dapat dilihat pada Gambar 4.26.

Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
zresid11	+.+	+.+	+.+	...
zresid21	..+	+.+
zresid31	..+

Gambar 4. 26 Representasi Skematik MPCCF Residual Data *Outflow*

Dalam penelitian ini karena model yang ingin dibentuk adalah VAR, maka identifikasi orde lebih ditekankan melalui skematik MPCCF. Pada Gambar 4.26 menunjukkan bahwa tanda positif (+) yang dominan muncul pada ketiga lokasi hanya pada lag ke-1, artinya data simulasi dari ketiga lokasi adalah pada VAR (1). Selain itu pemeriksaan orde AR (1) melalui nilai AIC minimum pada Tabel 4.9. Hal ini ditunjukkan dengan nilai minimum terdapat pada orde AR (1) dan MA (0).

Tabel 4. 8 Nilai AIC Residual TSR Data *Outflow*.

Lag	MA(0)	MA(1)	MA(2)	MA(3)	MA(4)	MA(5)
AR(0)	28,8693	28,7936	28,8071	28,8063	28,8871	28,9904
AR(1)	28,7165	28,7836	28,8799	28,8985	28,9769	29,0898
AR(2)	28,7595	28,8567	28,9940	29,0441	29,1080	29,2115
AR(3)	28,8534	28,9106	29,0370	29,1607	29,2389	29,3391
AR(4)	28,9602	28,9672	29,0792	29,2184	29,3055	29,3700
AR(5)	29,0796	29,0505	29,1502	29,2361	29,3523	29,5307

c. Estimasi Parameter Model VARX-SVR di Level Dua

Hasil estimasi model VAR (1) ditampilkan pada Lampiran 3 Tabel C. Maka model VAR (1) yang diperoleh adalah

i. KBI Bandung

$$N_t^{(1)*} = 0,1397N_{t-1}^{(1)} - 1,3793N_{t-1}^{(2)} - 0,0972N_{t-1}^{(3)} + a_t^{(1)} \quad (4.49)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = 0,1218N_{t-1}^{(2)} + 0,0093N_{t-1}^{(1)} - 0,0431N_{t-1}^{(3)} + a_t^{(2)} \quad (4.50)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,2783N_{t-1}^{(3)} + 0,0169N_{t-1}^{(1)} - 0,5193N_{t-1}^{(2)} + a_t^{(3)} \quad (4.51)$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *outflow* di KBI Bandung dipengaruhi oleh *outflow* KBI Tasikmalaya dan Cirebon satu bulan sebelumnya. Begitu juga *outflow* di KBI Tasikmalaya dan Cirebon memiliki interpretasi model yang sama dengan di KBI Bandung.

Hasil pemodelan SVR yang baik akan menghasilkan nilai RMSE pada data *out sample* yang terkecil. Untuk mendapatkan nilai RMSE yang kecil perlu dilakukan percobaan untuk mengkombinasikan nilai parameter epsilon, gamma, dan *cost* agar didapatkan nilai RMSE yang terbaik. Pada model VAR-SVR data

yang digunakan adalah sebanyak 132 data dengan data *out-sample* sebanyak 12 data terakhir. Kombinasi nilai parameter yang digunakan sama seperti pada studi simulasi. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel D. Tabel D menunjukkan nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,82363, yaitu dengan nilai epsilon 0,00006, nilai *cost* sebesar 351,50, dan nilai sigma sebesar 0,08. Pada KBI Tasikmalaya nilai MAPE terkecil sebesar 38,369195 dengan epsilon sebesar 0,0008, *cost* sebesar 351,5 dan nilai sigma sebesar 0,09. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00009, *cost* 350 dan sigma sebesar 0,10. Sehingga didapat persamaan VARX-SVR sebagai berikut,

i. KBI Bandung

$$\begin{aligned}\hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 351,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 193,12 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &351,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 201,92 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &- 110,51 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 351,5 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 34,081\end{aligned}\quad (4.52)$$


ii. KBI Tasikmalaya

$$\begin{aligned}\hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 82,93 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 20,77 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &100,49 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 58,47 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &37,92 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 91,21 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 4,8\end{aligned}\quad (4.53)$$

iii. KBI Cirebon

$$\begin{aligned}\hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 64,28 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 57,81 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &61,19 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 149,71 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &62,67 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 208,39 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 4,27\end{aligned}\quad (4.54)$$

Plot hasil peramalan pada data *in sample* (data *training*) dan *out sample* (data *testing*) seperti ditampilkan pada Gambar 4.27.



Gambar 4. 27 Time Series Hasil Peramalan Model VAR-SVR di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

Garis hitam pada Gambar 4.27 menunjukkan nilai yang sebenarnya, sedangkan garis ungu menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.26 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model VAR-SVR dengan parameter tersebut dapat memodelkan *outflow* dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada data *out-sample*

menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data *outflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.

d. Estimasi Parameter Model GSTARX-SVR di Level Dua

Tahap identifikasi dalam pemodelan GSTAR memiliki proses yang sama dengan pemodelan VAR dalam menentukan orde model. Sehingga, orde model GSTAR yang digunakan dalam analisis ini sama dengan orde dalam model VAR. Selanjutnya, pada estimasi tahap dua, model GSTAR dapat ditulis dalam bentuk GSTAR (1₁). Estimasi parameter yang digunakan adalah estimasi GLS dikarenakan data *inflow* dan *outflow* antar lokasi saling berkorelasi sehingga lebih efisien jika data yang berkorelasi diestimasi dengan GLS. Hal ini sesuai dengan studi simulasi, dimana metode estimasi GLS lebih baik dibandingkan OLS.

Penggunaan bobot dalam pemodelan GSTAR untuk masing-masing data *inflow* dan *outflow* terdapat tiga macam bobot, yaitu bobot seragam, invers jarak dan normalisasi inferensia korelasi silang parsial. Model yang digunakan adalah *full model* dengan semua estimasi parameter digunakan. Alasan penggunaan *full model* adalah model ini dinilai lebih baik dibandingkan *restricted model* (Amstrong, 2001). Selain itu, karena residual mendekati *white noise*, maka ketika dilakukan *restricted model*, akan ada lokasi yang tetap tidak signifikan. Berikut hasil analisis dan pembahasan yang dilakukan.

a) Bobot Seragam

Penerapan bobot seragam pada pemodelan GSTAR mengasumsikan bahwa *outflow* di KBI satu memiliki keterkaitan yang sama terhadap *outflow* di KBI lainnya. Sehingga pemberian bobot untuk KBI ke-*i* dan *j* adalah sama. matriks bobot seragam yang digunakan untuk melakukan estimasi parameter model GSTAR(2₁) dituliskan

$$\mathbf{W} = \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix}.$$

Secara lengkap hasil dari estimasi parameter dapat dilihat pada Lampiran 3 Tabel E. Sehingga model GSTAR (1₁) pada masing-masing lokasi dapat ditulis

i. KBI Bandung

$$N_t^{(1)*} = -0,067N_{t-1}^{(1)} + 0,039N_{t-1}^{(2)} + 0,039N_{t-1}^{(3)} + a_t^{(1)} \quad (4.55)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = 0,33N_{t-1}^{(2)} - 0,021N_{t-1}^{(1)} - 0,021N_{t-1}^{(3)} + a_t^{(2)} \quad (4.56)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,288N_{t-1}^{(3)} - 0,0448N_{t-1}^{(1)} - 0,0448N_{t-1}^{(2)} + a_t^{(3)} \quad (4.57)$$

Sama halnya dengan model VARX (1) sebelumnya, pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Tahap selanjutnya dilakukan pemodelan GSTARX-SVR. Kombinasi nilai parameter yang digunakan sama seperti studi simulasi. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel F. Sehingga didapat persamaan GSTARX-SVR sebagai berikut,

i. KBI Bandung

$$\begin{aligned} \hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 191,46 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 203,58 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &-112,16 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 350 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 35,738 \end{aligned} \quad (4.58)$$


ii. KBI Tasikmalaya

$$\begin{aligned} \hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 82,99 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 20,84 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &108,05 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 58,41 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &-6,922 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 91,15 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 4,74 \end{aligned} \quad (4.59)$$

iii. KBI Cirebon

$$\begin{aligned} \hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 64,988 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 57,11 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &61,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 146,38 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &63,38 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 207,69 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 3,57 \end{aligned} \quad (4.60)$$

Tabel G menunjukkan nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,36869, yaitu dengan nilai epsilon 0,00005, nilai *cost* sebesar 350, dan nilai sigma sebesar 0,1. Pada KBI Tasikmalaya nilai MAPE terkecil sebesar 38,36919 dengan epsilon sebesar 0,0007, *cost* sebesar 352,7 dan nilai sigma sebesar 0,05. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00008, *cost* 350 dan sigma sebesar 0,05. Plot hasil peramalan pada data *in sample* (data *training*) dan *out sample* (data *testing*) seperti ditampilkan pada Gambar 4.28.



Gambar 4. 28 Time Series Hasil Peramalan Model GSTARX-SVR Bobot Seragam di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

Garis hitam pada Gambar 4.28 menunjukkan nilai yang sebenarnya, sedangkan garis ungu menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.26 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTARX-SVR dengan parameter tersebut dapat memodelkan *outflow* dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada data *out-sample*

menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data *outflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.

b) Bobot Invers Jarak

Pemodelan GSTAR(1₁) dengan menggunakan bobot invers jarak mengasumsikan bahwa data *outflow* suatu lokasi dipengaruhi oleh jarak antara lokasi tersebut dengan lokasi lainnya. Jarak antara dua lokasi yang lebih jauh cenderung memiliki bobot yang lebih rendah dibandingkan dengan jarak antara dua lokasi yang lebih dekat. Matriks bobot invers jarak yang digunakan untuk mengestimasi atau menaksir parameter model GSTAR(3₁) dituliskan pada persamaan sebagai berikut.

$$\mathbf{W} = \begin{bmatrix} 0 & 0,453 & 0,547 \\ 0,496 & 0 & 0,504 \\ 0,449 & 0,551 & 0 \end{bmatrix}.$$

Berdasarkan parameter-parameter pada Lampiran E , maka dapat dibentuk persamaan untuk model GSTAR(1₁) dengan menggunakan bobot invers jarak untuk setiap lokasi sebagai berikut:

i. KBI Bandung

$$N_t^{(1)*} = -0,067N_{t-1}^{(1)} + 0,0255N_{t-1}^{(2)} + 0,031N_{t-1}^{(3)} + a_t^{(1)} \quad (4.61)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = 0,327N_{t-1}^{(2)} - 0,0196N_{t-1}^{(1)} - 0,0218N_{t-1}^{(3)} + a_t^{(2)} \quad (4.62)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,29N_{t-1}^{(3)} - 0,045N_{t-1}^{(1)} - 0,055N_{t-1}^{(2)} + a_t^{(3)} \quad (4.63)$$

Berdasarkan model yang terbentuk untuk *outflow* di setiap lokasi dapat diketahui bahwa pengaruh *outflow* di suatu lokasi dipengaruhi oleh *outflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda.

Tahap selanjutnya dilakukan pemodelan GSTARX-SVR. Kombinasi nilai parameter yang digunakan sama dengan sebelumnya. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel F. Terlihat bahwa nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,36869, yaitu dengan nilai epsilon 0,00005, nilai *cost* sebesar 350, dan nilai sigma sebesar 0,1. Pada KBI Tasikmalaya nilai MAPE

terkecil sebesar 38,36919 dengan epsilon sebesar 0,0007, *cost* sebesar 352,7 dan nilai sigma sebesar 0,05. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00008, *cost* 350 dan sigma sebesar 0,05.

Sehingga didapat persamaan GSTARX-SVR sebagai berikut,

i. KBI Bandung

$$\begin{aligned}
 \hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= 354,3 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 190,51 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &354,3 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 204,54 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
 &-113,12 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 354,3 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 36,69
 \end{aligned} \tag{4.64}$$

ii. KBI Tasikmalaya


$$\begin{aligned}
 \hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= 83,12 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 20,96 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &105,97 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 58,29 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
 &8,27 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 91,03 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 4,621
 \end{aligned} \tag{4.65}$$

iii. KBI Cirebon

$$\begin{aligned}
 \hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
 &= 64,988 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 57,11 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
 &61,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 146,38 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
 &63,38 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 207,69 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 3,57
 \end{aligned} \tag{4.66}$$

Plot hasil peramalan pada data *in sample* (data *training*) dan *out sample* (data *testing*) ditampilkan pada Gambar 4.26. Garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTARX-SVR dengan parameter tersebut dapat memodelkan *outflow* dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada data *out-sample* menunjukkan bahwa hasil peramalan cenderung

memiliki pola yang sama dengan data *outflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.



Gambar 4. 29 *Time Series* Hasil Peramalan Model GSTARX-SVR Bobot Invers Jarak di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

c) Bobot Normalisasi Korelasi Silang

Penerapan bobot normalisasi inferensia korelasi silang parsial pada pemodelan GSTAR(1)_t mengasumsikan bahwa keterkaitan *inflow* di suatu lokasi lebih dipengaruhi oleh tinggi rendahnya korelasi parsial yang dimiliki pada lokasi tersebut. Penghitungan bobot normalisasi inferensia korelasi silang parsial diperoleh melalui proses inferensia statistik yang dilakukan dengan menggunakan selang kepercayaan 95%, yaitu $t_{0,05/2;n-k-2} / \sqrt{n}$ dengan $n=132$ dengan lag ke- k .

Dikarenakan model yang digunakan adalah GSTAR(1₁) maka korelasi silang yang digunakan yang terdapat di lag 1. Hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 1, $r^{(ij)}(1)$, dapat dilihat pada Tabel 4.10.

Tabel 4. 9 Taksiran NIPKS antar Lokasi *Outflow* untuk Lag 1

Parameter	Estimasi	Taksiran interval 95%		Keputusan
		Batas bawah	Batas atas	
P ₁₂ (1)	0,1180	-0,0526	0,2886	Tidak Valid
P ₁₃ (1)	0,0595	-0,1111	0,2301	Tidak Valid
P ₂₁ (1)	-0,1676	-0,3382	0,0030	Tidak Valid
P ₂₃ (1)	-0,2146	-0,3852	-0,0440	Valid
P ₃₁ (1)	-0,0841	-0,2547	0,0865	Tidak Valid
P ₃₂ (1)	-0,0285	-0,1991	0,1421	Tidak Valid

Berdasarkan perhitungan dari hasil besaran korelasi silang antar lokasi pada waktu ke-1, proses inferensia statistik pada Tabel 4.10 menunjukkan bahwa taksiran interval menghasilkan batas yang tidak sama (tanda hubungan), sehingga memberikan keputusan tidak valid dan tidak sebanding, artinya tidak ada perbedaan untuk pemberian bobot antar lokasi. Namun ada satu lokasi yang memiliki nilai yang valid. Sehingga bobot yang digunakan adalah bobot seperti berikut

$$\mathbf{W}_1 = \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0 & 0 & -1 \\ 0,5 & 0,5 & 0 \end{bmatrix}.$$

Hasil penghitungan dengan estimasi parameter model GSTAR (1₁) dapat dilihat pada Lampiran 3 Tabel E. Model GSTAR(1₁) untuk $N_t^{(i)}$ *outflow* pada persamaan dapat dituliskan untuk tiap lokasi sebagai berikut

i. KBI Bandung

$$N_t^{(1)*} = 0,014N_{t-1}^{(1)} - 0,119N_{t-1}^{(2)} - 0,119N_{t-1}^{(3)} + a_t^{(1)} \quad (4.67)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = 0,301N_{t-1}^{(2)} - 0,077N_{t-1}^{(3)} + a_t^{(2)} \quad (4.68)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,238N_{t-1}^{(3)} - 0,03N_{t-1}^{(1)} - 0,03N_{t-1}^{(2)} + a_t^{(3)} \quad (4.69)$$

Tahap selanjutnya dilakukan pemodelan GSTARX-SVR. Kombinasi nilai parameter yang digunakan sama dengan simulasi. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel F. Terlihat bahwa nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,36869, yaitu dengan nilai epsilon 0,00005, nilai *cost* sebesar 350, dan nilai sigma sebesar 0,1. Pada KBI Tasikmalaya nilai MAPE terkecil sebesar 38,36919 dengan epsilon sebesar 0,0007, *cost* sebesar 352,7 dan nilai sigma sebesar 0,05. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00008, *cost* 350 dan sigma sebesar 0,05. Sehingga persamaan GSTARX-SVR sebagai berikut,

i. KBI Bandung

$$\begin{aligned}\hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 353,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 191,23 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &353,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 203,81 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &- 112,39 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 353,2 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 35,97\end{aligned}\quad (4.70)$$


ii. KBI Tasikmalaya

$$\begin{aligned}\hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 80,107 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) + 20,59 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &1050,31 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 58,65 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &37,89 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 144,106 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 4,986\end{aligned}\quad (4.71)$$

iii. KBI Cirebon

$$\begin{aligned}\hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 64,988 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 57,11 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &61,9 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 146,38 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &63,38 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 207,69 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 3,57\end{aligned}\quad (4.72)$$

Plot hasil peramalan pada data *in sample* (data *training*) dan *out sample* (data *testing*) ditampilkan pada Gambar 4.30.



Gambar 4. 30 Time Series Hasil Peramalan Model GSTARX-SVR Bobot NIKSP di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

Garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTARX-SVR dengan parameter tersebut dapat memodelkan *outflow* dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada data *out-sample* menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data *outflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.

4.2.3 Pemodelan Data *Inflow* Bank Indonesia

Sama seperti pada studi simulasi, penerapan pada data riil untuk estimasi parameter model GSTARX dilakukan dengan dua level dengan tahapan yang sama dengan data simulasi.

a. Estimasi Parameter Model Level 1

Data awal yang masih memuat efek variasi kalender seperti Gambar 4.22 perlu diatas terlebih dahulu dengan regresi *time series*, kemudian dilakukan pemeriksaan stasioneritas dan penentuan orde AR. Pada tahap ini dilakukan estimasi level satu, yaitu dengan cara melakukan regresi *time series*, sehingga diperoleh model $N_t^{(i)}$, dengan $i = 1, 2, 3$. Hasil dari estimasi parameter level satu diberikan dengan

i. KBI Bandung

$$\begin{aligned} Y_t^{(1)*} = & -2770,18D_{1,t}^{(1)} - 7851,15D_{2,t}^{(1)} + 29,63TD_{1,t}^{(1)} + 82,83TD_{2,t}^{(1)} + 2210,16S_{1,t}^{(1)} + \\ & 1434,63S_{2,t}^{(1)} + 1592,82S_{3,t}^{(1)} + 1386,52S_{4,t}^{(1)} + 1414,82S_{5,t}^{(1)} + 1271,12S_{6,t}^{(1)} + \\ & 1606,63S_{7,t}^{(1)} + 1857,66S_{8,t}^{(1)} + 1681,32S_{9,t}^{(1)} + 1561,64S_{10,t}^{(1)} + 1520,18S_{11,t}^{(1)} + \\ & 1004,55S_{12,t}^{(1)} + 871,77M_{3,t}^{(1)} + 2196,88M_{4,t}^{(1)} + 2215,41M_{1,t-1}^{(1)} + \\ & 1359,57M_{2,t-1}^{(1)} + N_t^{(1)}. \end{aligned} \quad (4.73)$$

Inflow mengalami efek variasi kalender Lebaran di KBI Bandung pada bulan yang terdapat Hari Raya Idul Fitri baik pada minggu ke 1,2,3 atau 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

ii. KBI Tasikmalaya

$$\begin{aligned} Y_t^{(2)*} = & 5,56T_t^{(2)} - 279,13D_{1,t}^{(2)} - 1257,51D_{2,t}^{(2)} - 4,55TD_{1,t}^{(2)} + 6,23TD_{2,t}^{(2)} + \\ & 471,98S_{1,t}^{(2)} + 394,63S_{2,t}^{(2)} + 431,05S_{3,t}^{(2)} + 395,66S_{4,t}^{(2)} + 409,12S_{5,t}^{(2)} + \\ & 394,99S_{6,t}^{(2)} + 477,08S_{7,t}^{(2)} + 476,76S_{8,t}^{(2)} + 472,99S_{9,t}^{(2)} + 457,66S_{10,t}^{(2)} + \\ & 444,3S_{11,t}^{(2)} + 324,38S_{12,t}^{(2)} + 290,91M_{1,t}^{(2)} + 324,1M_{2,t}^{(2)} + 475,67M_{2,t-1}^{(2)} + \\ & N_t^{(2)}. \end{aligned} \quad (4.74)$$

Efek variasi kalender Lebaran di KBI Tasikmalaya terjadi pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di


minggu ke-2, ke-3 atau ke-4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

iii. KBI Cirebon

$$Y_t^{(3)*} = -847,73D_{1,t}^{(3)} - 1894,66D_{2,t}^{(3)} + 6,23TD_{1,t}^{(3)} + 17,72TD_{2,t}^{(3)} + 1016,34S_{1,t}^{(3)} + 806,24S_{2,t}^{(3)} + 817,07S_{3,t}^{(3)} + 826,19S_{4,t}^{(3)} + 833,6S_{5,t}^{(3)} + 819,78S_{6,t}^{(3)} + 953,71S_{7,t}^{(3)} + 911,44S_{8,t}^{(3)} + 850,97S_{9,t}^{(3)} + 901,05S_{10,t}^{(3)} + 893,12S_{11,t}^{(3)} + 762,69S_{12,t}^{(3)} + 680,74M_{1,t}^{(3)} + 468,89M_{2,t}^{(3)} + 831,84M_{4,t-1}^{(3)} + N_t^{(3)}. \quad (4.75)$$

Inflow mengalami efek variasi kalender Lebaran di KBI Cirebon pada bulan yang terdapat Hari Raya Idul Fitri jika tanggal hari raya tersebut terdapat di minggu ke-2, 3 dan 4, atau terjadi 1 bulan sebelumnya jika tanggal hari raya tersebut terdapat di minggu ke-1 dan ke-2.

Pada tahap selanjutnya, residual tahap satu menjadi variabel respon di level 2. Residual dari tahap satu disajikan dalam matriks plot sebagai berikut,




Gambar 4. 31Matriks Plot Residual Data *Inflow*

Matriks plot pada Gambar 4.31 menunjukkan residual tahap pertama mengandung pola non linier. Maka dilakukan pemodelan non linier dengan SVR.

b. Identifikasi Orde Model Level 2

Bentuk model $N_t^{(i)}$ masing-masing lokasi ditunjukkan pada Gambar 4.32.



. **Gambar 4.32** Plot *Time Series Residual Inflow*, (a) Bandung, (b) Tasikmalaya dan (c) Cirebon

Dari model $N_t^{(i)}$ yang telah didapatkan, selanjutnya dilakukan pemeriksaan stasioneritas dan juga penentuan orde AR. Skematik MCCF pada Gambar 4.33 menunjukkan bahwa data telah stasioner. Hal ini terlihat dari banyaknya tanda (·) yang muncul..

Variable/ Lag	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
zresid12	+++
zresid22	+++
zresid32	+++

Gambar 4.33 Representasi Skematik MCCF Residual Data *Inflow*.

Setelah data stasioner, maka dilakukan penentuan orde model VAR dari plot MPCCF, yang hasilnya dapat dilihat pada Gambar 4.34.

Variable/ Lag	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
zresid12
zresid22
zresid32

Gambar 4.34 Representasi Skematik MPCCF Residual Data *Inflow*

Dalam penelitian ini karena model yang ingin dibentuk adalah VAR, maka identifikasi orde lebih ditekankan melalui skematik MPCCF. Pada Gambar 4.34 menunjukkan bahwa tanda positif (+) yang dominan muncul pada ketiga lokasi hanya pada lag ke-1, artinya data simulasi dari ketiga lokasi adalah pada VAR(1). Selain itu pemeriksaan orde AR(1) melalui nilai AIC minimum pada Tabel 4.10. Terlihat nilai minimum terdapat pada orde AR(1) dan MA(0).

Tabel 4.10 Nilai AIC Residual *Inflow*.

Lag	MA(0)	MA(1)	MA(2)	MA(3)	MA(4)	MA(5)
AR(0)	30,6144	30,6839	30,6768	30,6862	30,7720	30,8489
AR(1)	30,6118	30,6980	30,6926	30,7505	30,8136	30,9028
AR(2)	30,6160	30,6647	30,8008	30,8523	30,8787	30,9726
AR(3)	30,7376	30,7259	30,8660	30,9424	30,9796	31,1343
AR(4)	30,8465	30,7850	30,8698	30,9819	31,0897	31,2874
AR(5)	30,9567	30,8794	30,9954	31,1426	31,2284	31,4206

c. Estimasi Parameter Model VARX-SVR di Level Dua

Hasil estimasi model VAR(1) ditampilkan pada Lampiran 3 Tabel C. Maka model VAR(1) yang diperoleh adalah

i. KBI Bandung

$$N_t^{(1)*} = -0,122N_{t-1}^{(1)} - 0,713N_{t-1}^{(2)} + 0,549N_{t-1}^{(3)} + a_t^{(1)} \quad (4.76)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = 0,056N_{t-1}^{(2)} + 0,001N_{t-1}^{(1)} + 0,013N_{t-1}^{(3)} + a_t^{(2)} \quad (4.77)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,3N_{t-1}^{(3)} - 0,058N_{t-1}^{(1)} - 0,096N_{t-1}^{(2)} + a_t^{(3)} \quad (4.78)$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Misal, *inflow* di KBI Bandung dipengaruhi oleh *inflow* KBI Tasikmalaya dan Cirebon satu bulan sebelumnya. Begitu juga *inflow* di KBI Tasikmalaya dan Cirebon memiliki interpretasi model yang sama dengan di KBI Bandung.

Hasil pemodelan SVR yang baik akan menghasilkan nilai RMSE pada data *out sample* yang terkecil. Untuk mendapatkan nilai RMSE yang kecil perlu dilakukan percobaan untuk mengkombinasikan nilai parameter epsilon, gamma,

dan *cost* agar didapatkan nilai RMSE yang terbaik. Kombinasi nilai parameter yang digunakan sama seperti studi simulasi. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel F. Tabel E menunjukkan nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,82363, yaitu dengan nilai epsilon 0,00006, nilai *cost* sebesar 351,50, dan nilai sigma sebesar 0,08. Pada KBI Tasikmalaya nilai MAPE terkecil sebesar 38,369195 dengan epsilon sebesar 0,0008, *cost* sebesar 351,5 dan nilai sigma sebesar 0,09. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00009, *cost* 350 dan sigma sebesar 0,10. Sehingga didapat persamaan VARX-SVR sebagai berikut,

i. KBI Bandung

$$\begin{aligned}\hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= -201,88 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 247,63 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &19,13 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots + 355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &-355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) + 355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) + 67,422\end{aligned}\quad (4.79)$$


ii. KBI Tasikmalaya

$$\begin{aligned}\hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= 23,37 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 16,137 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &63,93 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 190,311 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &133,59 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 105,14 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) + 18,84\end{aligned}\quad (4.80)$$

iii. KBI Cirebon

$$\begin{aligned}\hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= -63,82 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 91,93 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &30,015 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 225,123 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &-354,3 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) + 107,288 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) + 18,86\end{aligned}\quad (4.81)$$

Plot hasil peramalan pada data *in sample* (data training) dan *out sample* (data testing) seperti ditampilkan pada Gambar 4.35.



Gambar 4. 35 Time Series Hasil Peramalan Model VAR-SVR di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

Terlihat pada Gambar 4.35 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model VAR-SVR dengan parameter tersebut dapat memodelkan *inflow* dengan baik. Sedangkan hasil peramalan untuk *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada *out-sample* menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data *inflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.

d. Estimasi Parameter Model GSTARX-SVR di Level Dua

Tahap identifikasi dalam pemodelan GSTAR memiliki proses yang sama dengan pemodelan VAR dalam menentukan orde model. Sehingga, orde model GSTAR yang digunakan dalam analisis ini sama dengan orde dalam model VAR. Selanjutnya, pada estimasi tahap dua, model GSTAR dapat ditulis dalam bentuk GSTAR(1₁). Berikut hasil analisis dan pembahasan yang dilakukan.

a) Bobot Seragam

Penerapan bobot seragam pada pemodelan GSTAR mengasumsikan bahwa *inflow* di KBI satu memiliki keterkaitan yang sama terhadap *inflow* di KBI lainnya. Sehingga pemberian bobot untuk KBI ke-*i* dan *j* adalah sama. Matriks bobot seragam yang digunakan untuk melakukan estimasi parameter model GSTAR(2₁) dituliskan

$$W = \begin{bmatrix} 0 & 0,5 & 0,5 \\ 0,5 & 0 & 0,5 \\ 0,5 & 0,5 & 0 \end{bmatrix}.$$

Secara lengkap hasil dari estimasi parameter dengan bobot seragam dapat dilihat pada Lampiran 3 Tabel E. Pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Sehingga model GSTAR (1₁) pada masing-masing lokasi dapat ditulis

i. KBI Bandung

$$N_t^{(1)*} = -0,11N_{t-1}^{(1)} + 0,089N_{t-1}^{(2)} + 0,089N_{t-1}^{(3)} + a_t^{(1)} \quad (4.86)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = 0,075N_{t-1}^{(2)} + 0,0013N_{t-1}^{(1)} + 0,0013N_{t-1}^{(3)} + a_t^{(2)} \quad (4.87)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,27N_{t-1}^{(3)} - 0,059N_{t-1}^{(1)} - 0,059N_{t-1}^{(2)} + a_t^{(3)} \quad (4.88)$$

Tahap selanjutnya dilakukan pemodelan GSTARX-SVR. Kombinasi nilai parameter yang digunakan sama seperti studi simulasi. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel F. Terihat bahwa nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,36869, yaitu dengan nilai epsilon 0,00005, nilai *cost* sebesar 350, dan nilai sigma sebesar 0,1. Pada KBI Tasikmalaya nilai MAPE terkecil sebesar 38,36919 dengan epsilon sebesar 0,0007, *cost* sebesar 352,7 dan

nilai sigma sebesar 0,05. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00008, *cost* 350 dan sigma sebesar 0,05. Sehingga didapat persamaan GSTARX-SVR sebagai berikut,

i. KBI Bandung

$$\begin{aligned}
\hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= -199,53 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 245,27 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&21,49 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
&-355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 69,77
\end{aligned} \tag{4.89}$$


ii. KBI Tasikmalaya

$$\begin{aligned}
\hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= 23,25 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 16,25 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&63,81 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 190,43 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
&-195,24 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) + 133,47 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 18,72
\end{aligned} \tag{4.90}$$

iii. KBI Cirebon

$$\begin{aligned}
\hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= -65,98 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 94,09 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&27,85 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 227,28 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
&-353,4 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) + 105,12 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 16,69
\end{aligned} \tag{4.91}$$

Plot hasil peramalan pada data *in sample* (data *training*) dan *out sample* (data *testing*) ditampilkan pada Gambar 4.26. Garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTARX-SVR dengan parameter tersebut dapat memodelkan *inflow* dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada data *out-sample* menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data *inflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.



Gambar 4. 36 Time Series Hasil Peramalan Model GSTARX-SVR Inflow Seragam di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

b) Bobot Invers Jarak

Pemodelan GSTAR(1_1) dengan menggunakan bobot invers jarak mengasumsikan bahwa data *inflow* suatu lokasi dipengaruhi oleh jarak antara lokasi tersebut dengan lokasi lainnya. Jarak antara dua lokasi yang lebih jauh cenderung memiliki bobot yang lebih rendah dibandingkan dengan jarak antara dua lokasi yang lebih dekat. Matriks bobot invers jarak yang digunakan untuk mengestimasi atau menaksir parameter model GSTAR(1_1) dituliskan pada persamaan sebagai berikut.

$$\mathbf{W} = \begin{bmatrix} 0 & 0,453 & 0,547 \\ 0,496 & 0 & 0,504 \\ 0,449 & 0,551 & 0 \end{bmatrix}.$$

Berdasarkan parameter-parameter pada Lmapiran , maka dapat dibentuk persamaan untuk model GSTAR(1₁) dengan menggunakan bobot invers jarak untuk setiap lokasi sebagai berikut:

i. KBI Bandung

$$N_t^{(1)*} = -0,109N_{t-1}^{(1)} + 0,080N_{t-1}^{(2)} + 0,097N_{t-1}^{(3)} + a_t^{(1)} \quad (4.92)$$

ii. KBI Tasikmalaya

$$N_t^{(2)*} = -0,109N_{t-1}^{(2)} + 0,0019N_{t-1}^{(1)} - 0,002N_{t-1}^{(3)} + a_t^{(2)} \quad (4.93)$$

iii. KBI Cirebon

$$N_t^{(3)*} = 0,274N_{t-1}^{(3)} - 0,0548N_{t-1}^{(1)} - 0,067N_{t-1}^{(2)} + a_t^{(3)} \quad (4.94)$$

Berdasarkan model yang terbentuk untuk *inflow* di setiap lokasi dapat diketahui bahwa pengaruh *inflow* di suatu lokasi dipengaruhi oleh *inflow* di lokasi tersebut atau dari lokasi lain dengan waktu yang berbeda. Tahap selanjutnya dilakukan pemodelan GSTARX-SVR. Kombinasi nilai parameter yang digunakan sama dengan studi simulasi. Berdasarkan hasil kombinasi nilai tersebut didapatkan nilai MAPE terkecil seperti pada Lampiran 3 Tabel F. Nilai MAPE pada data *out sample* di KBI Bandung yang terkecil adalah sebesar 71,36869, yaitu dengan nilai epsilon 0,00005, nilai *cost* sebesar 350, dan nilai sigma sebesar 0,1. Pada KBI Tasikmalaya nilai MAPE terkecil sebesar 38,36919 dengan epsilon sebesar 0,0007, *cost* sebesar 352,7 dan nilai sigma sebesar 0,05. Sedangkan di KBI Cirebon, MAPE terkecil sebesar 56,75073 dengan epsilon sebesar 0,00008, *cost* 350 dan sigma sebesar 0,05. Sehingga didapat persamaan GSTARX-SVR berikut,

i. KBI Bandung

$$\begin{aligned} \hat{Y}_t^{(1)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\ &= -198,59 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 244,33 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\ &22,43 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\ &-355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) - 355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 70,72 \end{aligned} \quad (4.95)$$


ii. KBI Tasikmalaya

$$\begin{aligned}
\hat{Y}_t^{(2)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= 18,74 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 16,23 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&63,83 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 190,40 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
&-195,22 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) + 133,50 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 18,74
\end{aligned} \tag{4.96}$$

iii. KBI Cirebon

$$\begin{aligned}
\hat{Y}_t^{(3)} &= \sum_{i=1}^{132} (\beta_i - \beta_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \\
&= -66,825 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_1 - \mathbf{x}\|^2\right) - 94,92 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_2 - \mathbf{x}\|^2\right) + \\
&27,01 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_3 - \mathbf{x}\|^2\right) + \dots - 228,12 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{130} - \mathbf{x}\|^2\right) + \\
&-355 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{131} - \mathbf{x}\|^2\right) + 104,28 \exp\left(-\frac{1}{2(0,05)^2} \|\mathbf{x}_{132} - \mathbf{x}\|^2\right) - 15,85
\end{aligned} \tag{4.97}$$

Plot hasil peramalan pada data *in sample* (data *training*) dan *out sample* (data *testing*) seperti ditampilkan pada Gambar 4.37. Garis hitam pada menunjukkan nilai yang sebenarnya, sedangkan garis ungu menunjukkan nilai hasil ramalan data *in-sample*. Terlihat pada Gambar 4.37 bahwa garis merah cenderung mengikuti pola dari garis hitam. Hal ini menunjukkan model GSTARX-SVR dengan parameter tersebut dapat memodelkan *inflow* dengan baik. Sedangkan hasil peramalan untuk data *out sample* ditampilkan pada plot dibawahnya. Hasil peramalan pada data *out-sample* menunjukkan bahwa hasil peramalan cenderung memiliki pola yang sama dengan data *inflow* yang sebenarnya, namun tidak terlihat berhimpit dengan data asli.



Gambar 4. 37 Time Series Hasil Peramalan Model GSTARX-SVR *Inflow* Invers Jarak di (a) KBI Bandung, (b) KBI Tasikmalaya dan (c) KBI Cirebon

c) Bobot Normalisasi Inferensia Parsial Korelasi Silang

Penerapan bobot normalisasi inferensia korelasi silang parsial pada pemodelan GSTAR(1₁) mengasumsikan bahwa keterkaitan *inflow* di suatu lokasi lebih dipengaruhi oleh tinggi rendahnya parsial korelasi yang dimiliki pada lokasi tersebut. Penghitungan bobot normalisasi inferensia korelasi silang parsial data *inflow* sama dengan sebelumnya pada data *outflow*. Dikarenakan model yang digunakan adalah GSTAR(1₁) maka korelasi silang yang digunakan yang terdapat di lag 1. Hasil perhitungan inferensia parsial korelasi silang antar lokasi pada lag 1 dapat dilihat pada Tabel 4.12. Berdasarkan perhitungan dari hasil besaran korelasi silang antar lokasi pada lag ke-1, proses inferensia statistik pada Tabel 4.12 menunjukkan bahwa taksiran interval menghasilkan batas yang tidak sama (tanda hubungan), sehingga memberikan keputusan tidak valid dan tidak sebanding,

artinya tidak ada perbedaan untuk pemberian bobot antar lokasi. Sehingga bobot yang digunakan adalah bobot seragam.

Tabel 4. 11 Taksiran NIPKS antar Lokasi *Inflow* untuk Lag 1

Parameter	Estimasi	Taksiran interval 95%		Keputusan
		Batas bawah	Batas atas	
$P_{12}(1)$	0,1685	-0,0021	0,3391	Tidak Valid
$P_{13}(1)$	-0,0739	-0,2445	0,0967	Tidak Valid
$P_{21}(1)$	-0,0643	-0,2349	0,1063	Tidak Valid
$P_{23}(1)$	0,0500	-0,1206	0,2206	Tidak Valid
$P_{31}(1)$	0,0246	-0,1460	0,1952	Tidak Valid
$P_{32}(1)$	-0,1219	-0,2925	0,0487	Tidak Valid

4.2.4 Pengujian Asumsi Residual Model VAR dan GSTAR

Pengujian asumsi residual *white noise* dilakukan untuk melihat kebaikan model yang digunakan dalam penelitian ini, yaitu VAR dan GSTAR. Pengujian ini dilakukan dengan cara memodelkan kembali residual dari model level 2 dan melakukan pemeriksaan nilai AIC minimum. Asumsi residual *white noise* terpenuhi apabila nilai AIC minimum terletak pada lag AR(0) dan MA(0) seperti yang ditunjukkan pada Tabel 4.13.

Tabel 4. 12 Nilai AIC Residual Model VAR dan GSTAR

Studi Skenario	Model	Bobot	Lag	AR(0)	AR(1)	AR(2)	AR(3)
Outflow	VARX		MA(0)	28,779	28,896	28,976	29,061
			MA(1)	28,903	28,985	29,069	29,099
	GSTARX	Seragam	MA(0)	28,835	28,921	28,975	29,065
			MA(1)	28,899	28,960	29,070	29,104
		Invers jarak	MA(0)	28,833	28,920	28,975	29,066
			MA(1)	28,899	28,960	29,070	29,104
		NIPKS	MA(0)	28,837	28,924	28,974	29,066
			MA(1)	28,904	28,963	29,071	29,103
Inflow	VARX		MA(0)	30,471	30,624	30,648	30,735
			MA(1)	30,690	30,715	30,663	30,766
	GSTARX	Seragam	MA(0)	30,479	30,616	30,647	30,738
			MA(1)	30,684	30,680	30,659	30,763
		Invers jarak	MA(0)	30,479	30,616	30,647	30,737
			MA(1)	30,683	30,679	30,659	30,763

Asumsi lainnya yang digunakan dalam pemodelan GSTAR adalah residual berdistribusi multivariat normal. Pengujian ini dilakukan untuk mengetahui apakah *error* dari model *time series* multivariat mengikuti distribusi multivariat normal atau tidak. Hipotesis awal yang digunakan adalah residual dari model berdistribusi multivariat normal. Hasil pengujian yang telah dilakukan ditampilkan pada Tabel 4.14.

Tabel 4. 13 Pengujian Residual Distribusi Multivariat Normal Model VAR dan GSTAR

Studi Skenario	Model	Bobot	Nilai p	Kesimpulan
<i>Outflow</i>	VAR		0,007	Tidak Normal Multivariat
	GSTAR	Seragam	0,0076	Tidak Normal Multivariat
		Invers jarak	0,0076	Tidak Normal Multivariat
		NIPKS	0,006	Tidak Normal Multivariat
<i>Inflow</i>	VAR		0,000	Tidak Normal Multivariat
	GSTAR	Seragam	0,000	Tidak Normal Multivariat
		Invers jarak	0,000	Tidak Normal Multivariat


Berdasarkan nilai p pada Tabel 4.14 yang lebih kecil dari $\alpha=0,05$, maka keputusan yang didapatkan dari hasil pengujian pada kedua model, yaitu VAR dan GSTAR(1₁) adalah menolak hipotesis nol, artinya residual tidak mengikuti distribusi multivariat normal pada ketiga bobot lokasi yang digunakan.

4.2.5 Pemilihan Model Terbaik Data Terapan

Setelah dilakukan pemodelan dengan menggunakan VARX, *hybrid* VARX-SVR, GSTARX dan *hybrid* GSTARX-SVR, maka didapatkan hasil ramalan untuk data *training* (*in-sample*) dan *testing* (*out-sample*). Selanjutnya, dapat dihitung nilai RMSE untuk masing-masing model seperti pada Lampiran 3 Tabel K.


Model terbaik adalah model dengan nilai RMSE *out-sample* terkecil, hal ini terkait dengan akurasi peramalan dari model yang telah dibangun terhadap model yang divalidasi. Nilai RMSE masing-masing model disajikan pada plot di Gambar 4.38. Nilai RMSE model *hybrid* VARX-SVR dan *hybrid* GSTARX-SVR terlihat baehimpitan. Begitupula dengan model VARX dan GSTARX yang juga terlihat memiliki nilai RMSE di kisaran yang sama. Pada data *training*, model *hybrid* VARX-SVR dan *hybrid* GSTARX-SVR memiliki nilai RMSE yang lebih

kecil daripada VARX dan GSTARX di data *inflow* maupun *outflow*. Namun hal serupa tidak terjadi pada data *testing*, model VARX dan GSTARX memiliki tingkat kesalahan ramalan yang lebih kecil dibandingkan model *hybrid* VARX-SVR dan *hybrid* GSTARX-SVR, kecuali pada lokasi dua data *inflow*



Gambar 4. 38 Nilai RMSE Keempat Model Data (a) *Outflow* dan (b) *Inflow*

Diantara sesama pemodelan linier, model VARX terlihat memiliki nilai RMSE yang lebih kecil dibandingkan model GSTARX. Pola ini diikuti oleh pemodelan non liniernya yaitu *Hybrid* VARX-SVR yang memiliki nilai RMSE lebih kecil dibandingkan *Hybrid* GSTARX-SVR.



Gambar 4. 39 Peningkatan Kebaikan Model *Hybrid* Dari Model Linier (a) *Outflow* dan (b) *Inflow*

Pada Gambar 4.39 terlihat bahwa model *hybrid* dengan SVR yang merupakan model non linier terlihat bekerja sangat baik pada data *training inflow* dan *outflow*. Pada data *training*, model *hybrid* VARX-SVR mampu menurunkan tingkat kesalahan ramalan VARX hingga 81% di data *outflow* dan 69% di data *inflow*. *Hybrid* GSTARX-SVR menurunkan tingkat kesalahan ramalan GSTAR sebesar 80% di data *outflow* dan 68% di data *inflow*. Namun pada data *testing*, *hybrid* GSTARX-SVR justru meningkatkan kesalahan ramalan GSTARX sebesar 56% di data *outflow* dan 10% di data *inflow*. Sedangkan model *hybrid* VARX-SVR meningkatkan kesalahan ramalan sebesar 57% dari model VARX di data *outflow* dan 10% di data *inflow*.

Pada data *inflow* dan *outflow*, model *hybrid* VARX-SVR dan GSTARX-SVR tidak lebih baik dibandingkan model VARX dan GSTARX di data *testing*. Keduanya meningkatkan kesalahan ramalan pada data *testing*, walaupun pada data *training* keduanya bekerja sangat baik, hal ini dikarenakan model *overfitting*.


Selanjutnya dipilih model terbaik untuk masing-masing lokasi untuk kemudian dilakukan peramalan dengan model terbaik. Kriteria yang digunakan adalah RMSE dan sMAPE pada data *testing*. Data *testing* dipilih karena berkaitan dengan akurasi ramalan.

Tabel 4. 14 Pemilihan Model Terbaik Data Terapan

Data	Metode	Bobot	sMAPE Testing		
			Y1	Y2	Y3
Outflow	VARX*		0,335917	0,195800	0,332762
	VARX-SVR		0,479572	0,295180	0,397689
	GSTARX	Seragam	0,339864	0,200129	0,338583
		Invers Jarak	0,339804	0,200066	0,338522
		NIKSP	0,338752	0,197526	0,337853
	GSTARX-SVR	Seragam	0,479572	0,295180	0,397689
		Invers Jarak	0,479572	0,295180	0,397689
		NIKSP	0,479572	0,295180	0,397689
	VARX		0,225814	0,383331	0,212051
Inflow	VARX-SVR		0,295873	0,263470	0,220199
	GSTARX	Seragam	0,226018	0,383364	0,212077
		Invers Jarak	0,226050	0,383370	0,212094
	GSTARX-SVR	Seragam	0,295832	0,263445	0,220199
		Invers Jarak	0,295816	0,263450	0,220199

Tabel 4.15 memperlihatkan untuk data *outflow* model terbaik adalah VARX di semua lokasi. Sedangkan untuk data *inflow* model terbaik di lokasi satu dan tiga adalah VARX, sedangkan di lokasi dua adalah GSTARX-SVR. Kriteria yang ditampilkan disini adalah sMAPE namun menghasilkan kesimpulan yang sama dengan kriteria RMSE. hal ini dapat dilihat dari Lampiran 3 Tabel G.

Untuk mengetahui sampai *k-step* ke berapa model VARX bisa memprediksi dengan baik data *inflow* dan *outflow* di tiap lokasi dapat dilihat pada Gambar 4.40.



Gambar 4. 40 Peramalan Baik Hingga *l*-Tahap Kedepan

Pemodelan data *inflow* dan *outflow* menggunakan VARX dan GSTARX-SVR bobot seragam sudah cukup baik, hal ini ditunjukkan oleh Gambar 4.40 dimana nilai RMSE di bawah nilai standar deviasi Untuk mengetahui sampai


berapa langkah ke depan model ini baik untuk meramalkan data *inflow* dan *outflow* dilihat dari RMSE *k-step*. Jika RMSE *k-step* berada dibawah standar deviasi maka ramalan *out sample* untuk *k-step* cukup baik. Namun jika berada di luar standar deviasi maka model tidak cukup bai dalam meramalkan data *out sample* sampai *k-step*.

Pada Gambar 4.40 terlihat bahwa ramalan *out sample* pemodelan VARX pada data *outflow* dapat meramal dengan baik hingga 7-tahap kedepan di ketiga lokasi. Pada 8-tahap kedepan ramalan tidak cukup baik,hal ini mengindikasikan bahwa adanya pola variasi kalender yang terjadi pada bulan Agustus yang masih belum bisa dimodelkan dengan baik. Sedangkan model VARX pada data *inflow* di KBI Bandung dan Cirebon dapat meramal dengan baik hingga 12-tahap kedepan. Pada model GSTARX-SVR di KBI Tasikmalaya terlihat hasil ramalan baik hingga 6-tahap kedepan. Pada 7-tahap kedepan ramalan tidak cukup baik, hal ini mengindikasikan bahwa adanya pola variasi kalender yang terjadi pada bulan Juli yang masih belum bisa dimodelkan dengan baik.

Pada bulan Agustus merupakan efek hari raya Idul Fitri yang terjadi pada minggu ke 4 bulan Juli, menyebabkan kenaikan nilai RMSE di masing-masing KPw BI wilayah Jawa Barat yang cukup tinggi sehingga melebihi nilai standar deviasi. Hal ini mengindikasikan bahwa ramalan model di masing-masing KPw BI wilayah Jawa Barat belum mampu menangkap pola variasi kalender dengan baik.

4.2.6 Peramalan *Out sample* Model Dua Level

Ramalan *out sample* untuk data *inflow* dan *outlow* dapat dilihat pada Lampiran 3 Tabel H. Plot ramalan *outsampel* untuk keempat model ditampilkan pada Gambar 4.41. Terlihat bahwa baik pada data *outflow* maupun *inflow*, model VARX dan GSTARX berhimpitan. Sedangkan model non linier VARX-SVR dan GSTARX-SVR juga berhimpitan. Seperti yang dijelaskan pada subbab sebelumnya, model linier VARX dan GSTARX dinilai lebih baik dalam data *testing* ditunjukkan oleh nilai RMSE yang lebih kecil.



Gambar 4. 41 Nilai Ramalan Keempat Model Data *Outflow* (kiri) dan *Inflow* (kanan) di (a) Bandung, (b) Tasikmalaya dan (c) Cirebon

Gambar 4.42 menampilkan plot dari data *training*, *testing* dan *forecast* hingga 2018 untuk data *inflow* dan *outflow* di ketiga lokasi dengan model terbaik. Terlihat bahwa garis merah dapat menangkap pola aktual yang ditunjukkan oleh garis hitam serta *forecast* cenderung mengalami tren peningkatan hingga tahun 2018. Namun tetap perlu diingat bahwa ramalan ini baik hingga beberapa tahap kedepan, seperti yang dijelaskan pada subbab sebelumnya.

Peramalan model *hybrid* didapatkan dari penjumlahan ramalan pada tahap satu dan tahap dua, seperti berikut,

$$\begin{aligned}
Z_t^{(1)} &= Y_t^{(1)*} + N_t^{(1)} \\
Z_t^{(2)} &= Y_t^{(2)*} + N_t^{(2)} \\
Z_t^{(3)} &= Y_t^{(3)*} + N_t^{(3)}
\end{aligned}$$

Model VARX KBI Bandung pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan pers. 4.49. Dengan

$$\begin{aligned}
Y_t^{(1)*} &= 19,68T_t^{(1)} - 1394,99D_{1,t}^{(1)} - 3263,84D_{2,t}^{(1)} + 20,04TD_{2,t}^{(1)} + 295,21S_{3,t}^{(1)} + \\
&351,61S_{4,t}^{(1)} + 315,21S_{5,t}^{(1)} + 609,57S_{6,t}^{(1)} + 687,52S_{7,t}^{(1)} + 314,56S_{8,t}^{(1)} + \\
&1239,59S_{12,t}^{(1)} + 1104,46M_{2,t}^{(1)} + 2490,87M_{3,t}^{(1)} + 2404,38M_{4,t}^{(1)} + \\
&2205,91M_{1,t-1}^{(1)} + 1252,35M_{2,t-1}^{(1)} + N_t^{(1)}. \\
N_t^{(1)*} &= 0,1397N_{t-1}^{(1)} - 1,3793N_{t-1}^{(2)} - 0,0972N_{t-1}^{(3)} + a_t^{(1)}
\end{aligned}$$

Begitupula untuk KBI Tasikmalaya dan KBI Cirebon yang didapatkan dari penjumlahan pers. 4.47-4.50 dan 4.48-4.51.

Peramalan *hybrid* VARX-SVR pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.52 untuk KBI Bandung, pers. 4.47 dan 4.53 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.54 untuk KBI Cirebon. Peramalan GSTARX dengan bobot seragam pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.55 untuk KBI Bandung, pers. 4.47 dan 4.56 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.57 untuk KBI Cirebon. Peramalan *hybrid* GSTARX-SVR dengan bobot seragam pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.58 untuk KBI Bandung, pers. 4.47 dan 4.59 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.60 untuk KBI Cirebon. Peramalan GSTARX dengan bobot invers jarak pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.61 untuk KBI Bandung, pers. 4.47 dan 4.62 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.63 untuk KBI Cirebon. Peramalan *hybrid* GSTARX-SVR dengan bobot invers jarak pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.64 untuk KBI Bandung, pers. 4.47 dan 4.65 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.66 untuk KBI Cirebon. Peramalan GSTARX dengan bobot NIKSP pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.67 untuk KBI Bandung, pers. 4.47 dan 4.68 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.69 untuk KBI Cirebon. Peramalan *hybrid* GSTARX-SVR dengan

bobot NIKSP pada data *outflow* didapatkan dari penjumlahan pers. 4.46 dan 4.70 untuk KBI Bandung, pers. 4.47 dan 4.71 untuk KBI Tasikmalaya serta penjumlahan pers. 4.48 dan 4.72 untuk KBI Cirebon.

Peramalan VARX pada data *inflow* didapatkan dari penjumlahan pers. 4.73 dan 4.76 untuk KBI Bandung, pers. 4.74 dan 4.77 untuk KBI Tasikmalaya serta penjumlahan pers. 4.75 dan 4.78 untuk KBI Cirebon. Peramalan *hybrid* VARX-SVR pada data *inflow* didapatkan dari penjumlahan pers. 4.73 dan 4.52 untuk KBI Bandung, pers. 4.74 dan 4.53 untuk KBI Tasikmalaya serta penjumlahan pers. 4.75 dan 4.54 untuk KBI Cirebon. Peramalan GSTARX dengan bobot seragam pada data *inflow* didapatkan dari penjumlahan pers. 4.46 dan 4.86 untuk KBI Bandung, pers. 4.74 dan 4.87 untuk KBI Tasikmalaya serta penjumlahan pers. 4.75 dan 4.88 untuk KBI Cirebon. Peramalan *hybrid* GSTARX-SVR dengan bobot seragam pada data *inflow* didapatkan dari penjumlahan pers. 4.46 dan 4.89 untuk KBI Bandung, pers. 4.74 dan 4.90 untuk KBI Tasikmalaya serta penjumlahan pers. 4.75 dan 4.91 untuk KBI Cirebon. Peramalan GSTARX dengan bobot invers jarak pada data *inflow* didapatkan dari penjumlahan pers. 4.46 dan 4.92 untuk KBI Bandung, pers. 4.74 dan 4.93 untuk KBI Tasikmalaya serta penjumlahan pers. 4.75 dan 4.94 untuk KBI Cirebon. Peramalan *hybrid* GSTARX-SVR dengan bobot invers jarak pada data *inflow* didapatkan dari penjumlahan pers. 4.73 dan 4.95 untuk KBI Bandung, pers. 4.74 dan 4.96 untuk KBI Tasikmalaya serta penjumlahan pers. 4.75 dan 4.97 untuk KBI Cirebon.

BAB 5

KESIMPULAN DAN SARAN

5.1 Kesimpulan

1. Model GSTAR-GLS memberikan parameter yang lebih efisien dibandingkan dengan GSTAR-OLS.
2. Model *time series* multivariat dua level pada data simulasi menghasilkan orde AR(1) untuk skenario residual linier dan AR(2) untuk skenario residual non linier. Pada studi simulasi, baik untuk residual linier maupun non linier diperoleh model VARX-SVR dan GSTARX-SVR merupakan model terbaik (*in sample*). Model VARX dan GSTARX merupakan model terbaik untuk *out sample*.
3. Model *time series* multivariat dua level pada data terapan menghasilkan orde AR(1) untuk data *outflow* dan data *inflow*. Model VARX merupakan model terbaik (*out sample*) untuk *outflow* di semua lokasi. Model terbaik (*out sample*) untuk data *inflow* adalah VARX untuk KBI Bandung dan KBI Cirebon serta GSTARX-SVR untuk KBI Tasikmalaya dengan bobot seragam.
4. Pada simulasi skenario satu, model *Hybrid* GSTARX-SVR mampu mengurangi kesalahan ramalan GSTARX sebesar 35%. Namun model *Hybrid* VARX-SVR justru meningkatkan kesalahan ramalan sebesar 12% dari model awal VARX. Pada simulasi skenario dua, dimana residual bersifat non linier, model *Hybrid* GSTARX-SVR mampu mengurangi kesalahan ramalan GSTARX sebesar 10%. Sedangkan model *Hybrid* VARX-SVR mengurangi kesalahan ramalan sebesar 8% dari model awal VARX.
5. Pada studi terapan, model *hybrid* dengan SVR yang merupakan model non linier terlihat bekerja sangat baik pada data *training inflow* dan *outflow*. Pada data *training*, model *hybrid* VARX-SVR mampu menurunkan tingkat kesalahan ramalan VARX hingga 81% di data *outflow* dan 69% di data *inflow*. *Hybrid* GSTARX-SVR menurunkan tingkat kesalahan ramalan GSTAR sebesar 80% di data *outflow* dan 68% di data *inflow*. Namun pada data *testing*, *hybrid* GSTARX-SVR justru meningkatkan kesalahan ramalan

GSTARX sebesar 56% di data *outflow* dan 10% di data *inflow*. Sedangkan model *hybrid* VARX-SVR meningkatkan kesalahan ramalan sebesar 57% dari model VARX di data *outflow* dan 10% di data *inflow*.

6. Pemodelan linier VARX lebih baik jika dibandingkan dengan GSTARX. Begitu pula dengan pemodelan *hybrid* non linier, model VARX-SVR lebih unggul daripada GSTARX-SVR.

5.2 Saran

Saran untuk penelitian selanjutnya berdasarkan penelitian yang telah dilakukan ini adalah

1. Ada kecenderungan data dengan periode yang lebih panjang dapat menangkap pola musiman dan variasi kalender dengan lebih baik, karena itu disarankan menambahkan data periode pengamatan.
2. Ada dugaan terdapat variabel lain yang mempengaruhi *inflow* dan *outflow* sehingga menambahkan variabel independen, misalnya inflasi atau kebijakan publik (intervensi) dapat dengan lebih baik memodelkan data *inflow* dan *outflow*.

DAFTAR PUSTAKA

- A.S.Nugroho, A.B.Witarto, & Handoko, D. (2003). Support Vektor Machine –Teori dan Aplikasi dalam Bioinformatika.
- Ahmad, I. S., Setiawan, Suhartono, & Masun, N. H. (2015). Forecasting of Monthly *Inflow* and *Outflow* Currency using Time Series Regression and ARIMAX: The Idul Fitri Effect. *American Institute of Physics*, 1691, 050002.
- Anggraeni, D., Prahutama, P., & Andari, S. (2013). Aplikasi Generalized Space-time Autoregressive (GSTAR) Pada Pemodelan Volume Kendaraan Masuk Tol Semarang. *Media Statistika*, Vol. 6, No. 2, 71-80.
- Apriliadara, M., Suhartono, & Prastyo, D. D. (2016). VARI-X Model for Currency *Inflow* and *Outflow* Forecasting with Eid Fitr Effect in Indonesia. *The 2016 Conference on Fundamental and Applied Science for Advanced Technology (ConFAST 2016)* (pp. 1-6). Yogyakarta: American Institute of Physics.
- Bank Indonesia. (2017). *Statistik*. Retrieved September 2, 2017, from Bank Indonesia: <http://www.bi.go.id/id/statistik/sistem-pembayaran/indikator-pengedaran-uang/Contents/Default.aspx>
- Borovkova, S., Lopuhaä, H., & Ruchjana, B. (2000). Consistency and Asymptotic Normality of Least Squares Estimators in Generalized STAR Models. *Statistica Neerlandica*.
- Borovkova, S., Lopuhaa, H., & Ruchjana, B. (2002). Generalized STAR Model With Experimental Weights. In M. S. Toulomi (Ed.), *Proceedings of the 17th International Workshop on Statistical Modeling*, (pp. 139-147). Chania.
- Boser, B., Guyon, I., & Vapnik, V. (1992). A *training* algorithm for optimal margin classifiers. *Proceedings of the Fifth Annual Workshop of Computational Learning Theory*. 5, pp. 144-152. Pittsburgh: ACM.
- Box, G. E., & Pierce, D. A. (1970). Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models. *Journal of the American Statistical Association*, 65, 1509-1526.
- Box, G., Jenkins, G., & Reinsel, G. (1994). *Time series analysis forecasting and control* (3rd ed.). New Jersey: Prentice-Hall Inc.
- Cliff, A., & Ord, J. (1973). *Spatial Autocorrelation*. London: Pioneer.
- Cortes, C., & Vapnik, V. (1995, September). Support-Vector Networks. (L. Saitta, Ed.) *Machine Learning*, 20, 273-279.

- Deng, M., & Athanasopoulos, G. (2009). *Modelling Australian Domestic and International Inbound Travel: a Spatial-Temporal Approach*. Monash University, Department of Econometrics and Business Statistics. Australia: VIC 3800.
- Direktur Penedaran Uang Bank Indonesia. (2011). *Surat Edaran Bank Indonesia No. 13/9/DPU Tanggal 5 April 2011 tentang Penyetoran dan Penarikan Uang Rupiah oleh Bank Umum di Bank Indonesia*. Bank Indonesia.
- Fina, A. M. (2016). *Peramalan Outflow Uang Kartal di Bank Indonesia Wilayah Jawa Tengah dengan Metode Geeneralized Space-time Autoregressive (GSTAR)*. Tugas Akhir, Universitas Diponegoro, Statistika, Semarang.
- Giacomini, R., & Granger, C. (2004). Aggregation of Space-Time Processes. *Journal of Econometrics*, Vol. 118, 7-26.
- Gunn, S. R., & Steve. (1998). *Support Vector Machine for Classification and Regression*. University of Southampton. ISIS.
- Guo, J., Yi, P., Wang, R., Ye, Q., Zhao, & Chunxia. (2014). Feature Selection for Least Sqaure Projection Twin Support Vector Machine. *Neurocomputing*, 14, 174-183.
- Haerdle, W., Prastyo, D., & Hafner, C. (2014). Support Vector Machines with Evolutionary Model Selection for Default Prediction. In J. Racine, L. Su, & A. Ullah, *The Oxford Handbook of Applied Nonparametric and Semiparametric Econometrics and Statistics* (pp. 346-373). Oxford University Press.
- Hong, W. (2008). Electric Load Forecasting by Support Vector Model. *Applied Mathematical Modelling*, 3, 2444-2454.
- Hurvich, C., & Tsai, C. (1989). Regression and Time Series Model Selection in Small Samples. *Biometrika*, 76, 297-307.
- Husna, F. (2013). *Pemodelan Generalized Space-time Autoregressive (GSTAR) dengan Menggunakan 4 Jenis Pembobot Lokasi (Studi Skenario Pada Inflasi Jabodetabek)*. Tugas Akhir, Universitas Brawijaya, Jurusan Matematika, Malang, Indonesia.
- Hyndman, J. D. (2006). *International Journal of Forecasting*. 22(3), 443-473.
- Ikoku, A. (2014). Modeling and Forecasting Currency in Circulation for Liquidity Management in Nigeria. *CBN Journal of Applied Statistics*, 5(1), 79-104.
- Ippoliti, L. (2001). On-line spatio-temporal prediction by a state space representation of the generalised space-time autoregressive model. *Metron*, LIX(1-2).
- Irawati, L., Tarno, & Yasin, H. (2015). Peramalan Indeks Harga Konsumen 4 Kota di Jawa Tengah Menggunakan Model Generalized Space-time Autoregressive (GSTAR). *Jurnal Gaussian*, 4(3), 553-562.

- Iriany, A., Suhariningsih., Ruchjana, B., & Setiawan. (2013). Prediction of Precipitation Data at Batu Town Using the GSTAR (1,p)-SUR Model. *Journal of Basic and Applied Scientific Research*, 3 (6), 860-865.
- Kamarianakis, Y., & Prastacos, P. (2005). Space-Time Modeling of Traffic flow. *Computers and Geosciences*, Vol. 31, 119-133.
- Karomah, A., & Suhartono. (2014). Peramalan Netflow Uang kartal dengan Model Variasi Kalender dan Model Autoregressive Distributed Lag (ARDL). *Sains dan Seni POMITS*, 3, 103-108.
- Kyryakidis, P., & Journel, A. (1999). Geostatistical Space-Time Model: A review. *Math. Geol.*, Vol. 31, No.6, 651-683.
- Lee, M., Suhartono, & Hamzah, N. (2010). Calendar Variation Model Based on ARIMAX for Forecasting Sales Data with Ramadhan Effect. *Proceedings of the Regional Conference on Statistical Sciences 2010 (RCSS'10)*, (pp. 349-361). Malaysia.
- Ljung, G. M., & Box, G. E. (1978). On a Measure of a Lack of Fit in Time Series Models. *Biometrika*, 65(2), 297-303.
- Maghfuro, L. (2012). *Peramalan Model Curah Hujan di Kabupaten Malang dengan Pendekatan Model Univariate Time Series dan Multivariate Time Series*. Tugas Akhir, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.
- Maharesi, R. (2013). Penggunaan Support Vector Regression (SVR) Pada Prediksi Return Saham Syariah BEI. *Proceeding PESAT (Psikologi, Ekonomi, Sastra, Arsitektur & Teknik Sipil)*, 5, pp. 178-186. Bandung.
- Manager Divisi Asesmen Ekonomi dan Keuangan Kantor Perwakilan Bank Indonesia Wilayah IV. (2017). *Kajian Ekonomi Regional Jawa Barat Triwulan II – 2017*. Kantor Perwakilan Bank Indonesia Wilayah II.
- Manager Divisi Statistik Moneter dan Fiskal Bank Indonesia. (2013). *Komunikasi Personal Juli 2013*. Jakarta: Bank Indonesia.
- Mubarak, R. (2015). *Model Generalized Space-Time Autoregressive With Exogenous Variables Untuk Peramalan Arus Uang di Bank Indonesia Wilayah Jawa Timur*. Tesis, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.
- Muhtaram, L. (2011). Retrieved September 2, 2017, from Metris Community [Online]: <http://www.metriscommunity.com/pengertian data mining-konsep pdf/>
- Nabila, F. S. (2016). *Pemodelan Vector Autoregressive - Support Vector Regression (VAR-SVR) dan Generalized Space-time Autoregressive - Support Vector Regression (GSTAR-SVR) Untuk Peramalan Curah Hujan di Kota Surabaya*. Tugas Akhir, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.

- Ningrum, S. P. (2010). *Pemodelan Spatio-Temporal dengan Metode GSTAR pada Data Curah Hujan Bulanan di Kabupaten Ngawi*. Tugas Akhir, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.
- Nugroho. (2008). Support Vector Machine: Paradigma Baru dalam softcomputing dan Aplikasinya. *Konferensi Nasional Sistem & Informatika*. Bali.
- Nurhayati, N., Pasaribu, U. S., & Neswan, O. (2012). Application of Generalized Space-Time Autoregressive Model on GDP Data in West European Countries. *Journal of Probability and Statistics*.
- Nurhayati, S., Kusrini, & Luthfi, E. T. (2015). Prediksi Mahasiswa Drop Out Menggunakan Metode Support Vector Machine. *Jurnal Ilmiah SISFOTENIKA*, 5(1).
- Oeppen, R. L., & Martin, J. (1975). The identification of regional forecasting. *Transactions of the Institute of British Geographers*, 66, 119–128.
- Parker, P., & Swindlehurst, A. (2003). Space-Time Autoregressive Filtering for Matched Subspace STAP. *IEEE Transactions on Aerospace and Electronic Systems*, vol. 39, No. 2.
- Pena, D., & Rodriguez, J. (2002). A Powerful Portmanteau Test of Lack of Fit for Time Series. *Journal of the American Statistical Association*, 97(458), 601-610.
- Pfeifer, P., & Deutsch, S. (1980a). A Three Stage Iterative Procedure for Space-Time Modeling. *Technometrics*, 22(1), 35-47.
- Pfeifer, P., & Deutsch, S. (1980b). Identification and Interpretation of First Order Space-Time ARMA Models. *Technometrics*, 22 (1), 397-408.
- Pramono, B., Yanuarti, T., Purusitawati, P., & Emmy, Y. (2006). *Dampak Pembayaran Non Tunai Terhadap Perekonomian Dan Kebijakan Moneter*. Jakarta: Bank Indonesia.
- Prasetyo, E. (2014). *Data Mining Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: Andi.
- Prastuti, M. (2014). *Model GSTAR-SUR Musiman untuk Peramalan Jumlah Wisatawan Mancanegara di Empat Lokasi Wisata di Indonesia*. Tesis, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.
- Prisandy, D., & Suhartono. (2008). Penerapan Metode GSTAR (P1) untuk Meramalkan Data Penjualan Rokok di Tiga Lokasi. *Jurnal Ilmiah Widya Teknik*, 7(2), 199-210.
- Rahman, F., & Purnami, W. S. (2012, September). Perbandingan Klasifikasi Tingkat Keganasan Breast Cancer Dengan Menggunakan Regresi Logistik Ordinal dan Support Vector Machine (SVM). *Jurnal SAINS dan Seni ITS*, 1(1).

- Ramos, R. (2003). Forecasts of Market Shares From VAR and BVAR Models: A Comparison of Their Accuracy. *International Journal of Forecasting*, 19, 95-110.
- Reganata, G. P., & Suhartono. (2015). *Peramalan Inflow dan Outflow Uang Kartal dengan Fungsi Transfer Multi Input and Neural Network*. Thesis, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.
- Ruchjana, B. (2001). Study on the Weight Matrix in the Space-Time Autoregression Model. In G. Govarett (Ed.), *Proceeding of Tenth International Symposium on Applied Stochastic Models and Data Analysis*. Vol. 2, No. 2, pp. 789-794. France: Universite de Technologie de Compiegne.
- Ruchjana, B. (2002). Pemodelan Kurva Produksi Minyak Bumi Menggunakan. *Forum Statistika dan Komputasi*. Bogor: IPB.
- Safitri, R., Setiawan, & Ahmad, I. S. (2016). Peramalan *Outflow* Uang Pecahan di Jawa Timur Menggunakan Generalized Space-time Autoregressive (GSTAR). *JURNAL SAINS DAN SENI ITS*, 5(2), 259-264.
- Santosa, B. (2007). *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.
- Setiawan, Suhartono, Ahmad, I. S., & Rahmawati, N. I. (2015). Configuring calendar variation based on time series regression method for forecasting of monthly currency *inflow* and *outflow* in Central Java. *Innovation and Analytics Conference and Exhibition (IACE 2015)* (pp. 1-8). Kedah, Malaysia: American Institute of Physics.
- Shoesmith, G. (2013). Space-Time Autoregressive Models and Forecasting National, Regional and State Crime Rates. *International Journal of Forecasting*, 29, 191 – 201.
- Sigalingging, H., Setiawan, E., & Sihalo, H. (2004). *Kebijakan Pengedaran Uang Di Indonesia*. Jakarta: Pusat Pendidikan dan Studi Kebanksentralan (PPSK) Bank Indonesia.
- Suharsono, A., Suhartono, Masyitha, A., & Anuravega, A. (2015). Time series regression and ARIMAX for forecasting currency flow at Bank Indonesia in. *Innovation and Analytics Conference and Exhibition (IACE 2015)* (pp. 1-8). Kedah, Malaysia: American Institute of Physics.
- Suhartono. (2003). *Penerapan dan perbandingan model State-Space dengan model Space-Time STAR untuk peramalan data deret waktu dan lokasi*. ITS, Surabaya: LEMLIT.
- Suhartono. (2005). Evaluasi pembentukan model VARIMA dan STAR untuk peramalan data *time series* dan lokasi. *Workshop and National Seminar on Space-time Models and Its Application*. Bandung: UNPAD.

- Suhartono. (2006). Perbandingan antara model VARIMA dan GSTAR untuk peramalan data *time series* dan lokasi,. *Prosiding Seminar Nasional Statistika*. Surabaya: ITS.
- Suhartono, & Atok, R. M. (2006). Pemilihan bobot lokasi yang optimal pada model GSTAR. *National Mathematics Conference XIII*. Semarang: Universitas Negeri Semarang.
- Suhartono, & Lee, M. (2011). Two Levels Regression Modelling of Trading Day and Holiday Effects for Forecasting Retail Data. *International Conference on Mathematics, Statistics and Its Applications (ICMSA 2011)*, (pp. 150-164).
- Suhartono, & Subanar. (2006). The Optimal Determination of Space Weight in GSTAR Model by using Cross-correlation Inference. *JOURNAL OF QUANTITATIVE METHODS: Journal Devoted to The Mathematical and Statistical Application in Various Fields*, 2(2), 45-53.
- Suhartono, & Subanar. (2007). Some Comments on the Theorem Providing Stasionerity Condition for GSTAR Models in the Paper by Borovkova et al. *Journal of The Indonesian Mathematical Siciety (MIHMI)*, 13(1), 44-52.
- Suhartono, Lee, M., & Hamzah, N. (2010). Calendar Variation Model Based on Time Series Regression for Sales Forecasts: The Ramadhan Effect. *Proceedings of the Regional Conference on Statistical Sciences 2010 (RCSS'10)*, (pp. 30-41).
- Suhartono, Lee, M., & Prastyo, D. (2015). Two Levels ARIMAX and Regression Models for Forecasting Time Series Data with Calendar Variation Effects. In A. e. Ibrahim (Ed.), *The 2nd Innovation and Analytics Conference & Exhibition*. Kedah: American Institute of Physics.
- Terzi, S. (1995). Maximum Likelihood Estimation of a GSTAR(1;1) Model. *Statistical Methods and Applications*, 3, 377-393.
- Tiao, G. C., & Box, G. E. (1981, December). Modeling Multiple Time Series with Applications. *Journal of the American Statistical Association*, 76(376), 802-816.
- Tsay, R. (2002). *Analysis of Financial Time Series: Financial Econometrics* (2nd ed.). University of Chicago: John Wiley & Sons, Inc.
- Tsay, R. (2005). *Analysis of Financial Time Series : Financial Econometrics*. University of Chicago, USA: John Wiley & Sons, Inc.
- Tsay, R. (2014). *Multivariate Time Series Analysis*. Chicago: John Wiley, Inc.
- Vapnik, V. (1998). *The Nature of Statistical Learning* (2nd ed.). New York: Springer.
- Wahyuningrum, S. (2014). *Model GSTARX-GLS untuk Peramalan Data Spatio-Temporal*. Tesis, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.

- Wei, W. (2006). *Time Series Analysis: Univariate and Multivariate* (2nd ed.). USA: Pearson Education, Inc.
- Wulansari, R., & Suhartono. (2014). Peramalan Netflow Uang Kartal dengan Metode ARIMAX dan Radial Basis Function Network (Studi Skenario Di Bank Indonesia). *Jurnal Sains dan Seni POMITS*, 3(2), 73-78.
- Wulansari, R., & Suhartono. (2017). *Peramalan Outflow Tiap Pecahan Uang Kartal dengan Metode ARIMAX, HYBRID ARIMAX-ANN, dan VARI-X (Studi Skenario Bank Indonesia Regional Surabaya)*. Tesis, Institut Teknologi Sepuluh Nopember, Statistika, Surabaya.
- Wulansari, R., Suryanto, E., Ferawati, K., Andalita, I., & Suhartono. (2014). Penerapan Time Series Regression with Calendar Variation Effect pada Data Netflow Uang Kartal Bank Indonesia Sebagai Solusi Kontrol Likuiditas Perbankan di Indonesia. *Statistika*, 14(2), 59-68.
- Wutsqa, D. (2010). Metode Pembentukan Model Generalized Space-time Autoregressive dan Aplikasinya untuk Peramalan Data Pencemaran Udara di Kota Surabaya. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Application (ICMSA 2010)*. Yogyakarta: Universitas Negeri Yogyakarta.
- Wutsqa, D. U., & Suhartono. (2010). Seasonal Multivariate Time Series Forecasting On Tourism Data By Using VAR-GSTAR Model. *Jurnal ILMU DASAR*, vol. 11, No. 1, 101-109.
- Wutsqa, D., Suhartono, & Sutijo, B. (2010). Generalized Space-Time Autoregressive Modelling. *Proceedings of the 6th IMT-GT Conference on Mathematics, Statistics and its Applications (ICMSA2010)* (pp. 752 – 761). Kuala Lumpur, Malaysia: Universiti Tunku Abdul Rahman.
- Yasin, H., Prahutama, A., & Utami, T. (2014). rediksi Harga Saham Menggunakan Support Vector Regression dengan Algoritma Grid Search. *Media Statistika*, Vol. 7 No. 1.
- Zhang, G. (2003). Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.

LAMPIRAN

LAMPIRAN 1 Studi Simulasi Residual Linier

Tabel A Estimasi parameter model level satu dengan residual linier

Lokasi	OLS		GLS		Efisiensi (%)
	Estimasi	SE	Estimasi	SE	GLS
1	t	0,209	0,001	0,209	0,001
	S1	22,025	0,317	22,025	0,317
	S2	23,974	0,318	23,974	0,318
	S3	27,006	0,319	27,006	0,319
	S4	24,118	0,319	24,118	0,319
	S5	22,095	0,319	22,095	0,319
	S6	17,181	0,319	17,181	0,319
	S7	13,519	0,320	13,519	0,320
	S8	10,262	0,320	10,262	0,320
	S9	6,240	0,320	6,240	0,320
	S10	10,027	0,321	10,027	0,321
	S11	13,199	0,321	13,199	0,321
	S12	17,128	0,321	17,128	0,321
	M1t	32,406	0,615	32,406	0,615
	M2t	43,572	0,543	43,572	0,543
	M3t	46,445	0,575	46,445	0,575
	M4t	48,612	0,543	48,612	0,543
	M1t1	49,906	0,615	49,906	0,615
	M2t1	46,388	0,543	46,388	0,543
	M3t1	38,715	0,576	38,715	0,576
	M4t1	33,338	0,543	33,338	0,543
2	T	0,229	0,001	0,229	0,001
	S1	25,087	0,299	25,087	0,299
	S2	28,086	0,300	28,086	0,300
	S3	30,290	0,301	30,290	0,301
	S4	28,146	0,301	28,146	0,301
	S5	25,003	0,301	25,003	0,301
	S6	21,333	0,301	21,333	0,301
	S7	16,409	0,302	16,409	0,302
	S8	13,238	0,302	13,238	0,302
	S9	9,206	0,302	9,206	0,302
	S10	13,259	0,303	13,259	0,303
	S11	16,071	0,303	16,071	0,303
	S12	21,110	0,303	21,110	0,303
	M1t	45,392	0,581	45,392	0,581

Lokasi	OLS		GLS		Efisiensi (%)	
	Estimasi	SE	Estimasi	SE	GLS	
3	M2t	49,710	0,512	49,710	0,512	0,000
	M3t	54,147	0,543	54,147	0,543	0,000
	M4t	56,715	0,512	56,715	0,512	0,000
	M1t1	59,613	0,581	59,613	0,581	0,000
	M2t1	54,309	0,512	54,309	0,512	0,000
	M3t1	43,480	0,543	43,480	0,543	0,000
	M4t1	35,899	0,512	35,899	0,512	0,000
	T	0,239	0,001	0,239	0,001	0,000
	S1	17,207	0,260	17,207	0,260	0,000
	S2	21,142	0,261	21,142	0,261	0,000
	S3	23,996	0,261	23,996	0,261	0,000
	S4	21,104	0,262	21,104	0,262	0,000
	S5	17,149	0,261	17,149	0,261	0,000
	S6	12,224	0,262	12,224	0,262	0,000
	S7	9,292	0,262	9,292	0,262	0,000
	S8	6,192	0,262	6,192	0,262	0,000
	S9	4,338	0,262	4,338	0,262	0,000
	S10	6,221	0,263	6,221	0,263	0,000
	S11	9,210	0,263	9,210	0,263	0,000
	S12	12,237	0,264	12,237	0,264	0,000
M1t	37,421	0,505	37,421	0,505	0,000	
M2t	40,560	0,445	40,560	0,445	0,000	
M3t	46,435	0,472	46,435	0,472	0,000	
M4t	50,746	0,445	50,746	0,445	0,000	
M1t1	48,900	0,505	48,900	0,505	0,000	
M2t1	47,201	0,445	47,201	0,445	0,000	
M3t1	40,599	0,472	40,599	0,472	0,000	
M4t1	36,477	0,445	36,477	0,445	0,000	

Tabel B Koefisien parameter model level satu TSR-GLS residual linier

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas	Batas	
					bawah	atas	
1	T	0,21	0,209	0,001	0,208	0,210	Benar
	S1	22	22,025	0,317	21,403	22,647	Benar
	S2	24	23,974	0,318	23,351	24,596	Benar
	S3	27	27,006	0,319	26,382	27,630	Benar
	S4	24	24,118	0,319	23,493	24,743	Benar
	S5	22	22,095	0,319	21,471	22,720	Benar
	S6	17	17,181	0,319	16,556	17,806	Benar
	S7	13	13,519	0,320	12,892	14,146	Benar
	S8	10	10,262	0,320	9,635	10,888	Benar
	S9	6	6,240	0,320	5,613	6,868	Benar
	S10	10	10,027	0,321	9,398	10,656	Benar
	S11	13	13,199	0,321	12,569	13,828	Benar
	S12	17	17,128	0,321	16,498	17,758	Benar
	M1t	32	32,406	0,615	31,200	33,612	Benar
	M2t	43	43,572	0,543	42,509	44,636	Benar
	M3t	47	46,445	0,575	45,317	47,573	Benar
	M4t	49	48,612	0,543	47,548	49,676	Benar
	2	M1t1	50	49,906	0,615	48,701	51,112
M2t1		46	46,388	0,543	45,324	47,452	Benar
M3t1		39	38,715	0,576	37,587	39,843	Benar
M4t1		34	33,338	0,543	32,274	34,402	Benar
T		0,23	0,229	0,001	0,227	0,230	Benar
S1		25	25,087	0,299	24,500	25,674	Benar
S2		28	28,086	0,300	27,498	28,673	Benar
S3		30	30,290	0,301	29,700	30,879	Benar
S4		28	28,146	0,301	27,556	28,736	Benar
S5		25	25,003	0,301	24,414	25,593	Benar
S6		21	21,333	0,301	20,743	21,923	Benar
S7		16	16,409	0,302	15,817	17,000	Benar
S8		13	13,238	0,302	12,647	13,830	Benar
S9		9	9,206	0,302	8,614	9,798	Benar
S10		13	13,259	0,303	12,666	13,853	Benar
S11		16	16,071	0,303	15,477	16,666	Benar
S12		21	21,110	0,303	20,515	21,705	Benar
M1t		45	45,392	0,581	44,254	46,531	Benar
M2t	49	49,710	0,512	48,706	50,714	Benar	
M3t	55	54,147	0,543	53,082	55,212	Benar	
M4t	57	56,715	0,512	55,711	57,719	Benar	
M1t1	60	59,613	0,581	58,475	60,752	Benar	
M2t1	54	54,309	0,512	53,305	55,313	Benar	

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
3	M3t1	44	43,480	0,543	42,415	44,545	Benar
	M4t1	36	35,899	0,512	34,895	36,904	Benar
	T	0,24	0,239	0,001	0,238	0,240	Benar
	S1	17	17,207	0,260	16,697	17,717	Benar
	S2	21	21,142	0,261	20,631	21,653	Benar
	S3	24	23,996	0,261	23,484	24,509	Benar
	S4	21	21,104	0,262	20,591	21,617	Benar
	S5	17	17,149	0,261	16,636	17,661	Benar
	S6	12	12,224	0,262	11,711	12,737	Benar
	S7	9	9,292	0,262	8,777	9,806	Benar
	S8	6	6,192	0,262	5,679	6,706	Benar
	S9	4	4,338	0,262	3,824	4,853	Benar
	S10	6	6,221	0,263	5,705	6,737	Benar
	S11	9	9,210	0,263	8,694	9,727	Benar
	S12	12	12,237	0,264	11,721	12,754	Benar
	M1t	37	37,421	0,505	36,432	38,410	Benar
	M2t	40	40,560	0,445	39,688	41,433	Benar
	M3t	47	46,435	0,472	45,509	47,360	Benar
	M4t	51	50,746	0,445	49,873	51,618	Benar
	M1t1	49	48,900	0,505	47,911	49,889	Benar
	M2t1	47	47,201	0,445	46,329	48,074	Benar
	M3t1	41	40,599	0,472	39,674	41,525	Benar
	M4t1	37	36,477	0,445	35,604	37,350	Benar

Tabel C Estimasi parameter model VAR di level dua residual linier


Lokasi	Parameter	Estimasi	<i>Standard Error</i>	t Value	P-Value	Variabel
zresid11	AR1_1_1	0,2781	0,0694	4,01	0,0001	zresid11(t-1)
	AR1_1_2	0,2858	0,0730	3,91	0,0001	zresid21(t-1)
	AR1_1_3	0,3784	0,0975	3,88	0,0001	zresid31(t-1)
zresid21	AR1_2_1	0,1185	0,0506	2,34	0,0198	zresid11(t-1)
	AR1_2_2	0,4208	0,0533	7,9	0,0001	zresid21(t-1)
	AR1_2_3	0,4431	0,0711	6,23	0,0001	zresid31(t-1)
zresid31	AR1_3_1	0,1339	0,0544	2,46	0,0142	zresid11(t-1)
	AR1_3_2	0,1971	0,0572	3,44	0,0006	zresid21(t-1)
	AR1_3_3	0,4802	0,0764	6,29	0,0001	zresid31(t-1)

Tabel D Estimasi parameter model VARX-SVR residual linier


Lokasi	Epsilon	Cost	Sigma	Error	MAPE	MAPEp
1	0,00007	350,00	0,06	0,75673	1,31381	0,68600
	0,00005	350,60	0,06	0,75668	1,31373	0,68605
	0,00005	351,10	0,06	0,75669	1,31374	0,68606
	0,00006	350,10	0,06	0,75673	1,31380	0,68606
	0,00008	350,00	0,06	0,75671	1,31378	0,68607
2	0,00006	354,80	0,07	0,72912	1,34174	0,82760
	0,00005	354,00	0,07	0,72912	1,34172	0,82760
	0,00008	354,50	0,07	0,72912	1,34173	0,82760
	0,00009	354,50	0,07	0,72915	1,34173	0,82760
	0,00008	355,00	0,07	0,72911	1,34173	0,82761
3	0,00008	352,70	0,06	0,74836	1,38547	0,63646
	0,00005	351,70	0,06	0,74836	1,38549	0,63646
	0,00009	353,70	0,06	0,74835	1,38563	0,63647
	0,00007	351,00	0,06	0,74836	1,38548	0,63647
	0,00009	351,80	0,06	0,74836	1,38549	0,63647

Tabel E Plot Aktual dan Ramalan Model VARX-SVR residual linier


Replikasi 1




Replikasi 2




Replikasi 3




Replikasi 4




Replikasi 5




Replikasi 6




Replikasi 7




Replikasi 8



Replikasi 9



Replikasi 10



Tabel F Estimasi parameter model GSTAR di level dua residual linier

Lokasi	Parameter	OLS		GLS		Efisiensi (%)
		Estimasi	SE	Estimasi	SE	GLS
1	ϕ_{10}^1	0,288	0,068	0,357	0,051	0,246
	ϕ_{11}^1	0,324	0,079	0,285	0,060	0,232
2	ϕ_{20}^1	0,458	0,052	0,452	0,042	0,195
	ϕ_{21}^1	0,246	0,056	0,249	0,046	0,181
3	ϕ_{30}^1	0,481	0,076	0,370	0,053	0,306
	ϕ_{31}^1	0,164	0,067	0,211	0,048	0,286

Tabel G Koefisien model level dua GSTAR-GLS residual linier


Parameter	Koefisien		SE	CI 95%		Keterangan
	Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
ϕ_{10}^1	0,35	0,357	0,051	0,257	0,457	Benar
ϕ_{11}^1	0,3	0,285	0,060	0,166	0,403	Benar
ϕ_{20}^1	0,45	0,452	0,042	0,369	0,535	Benar
ϕ_{21}^1	0,25	0,249	0,046	0,160	0,339	Benar
ϕ_{30}^1	0,4	0,370	0,053	0,266	0,475	Benar
ϕ_{31}^1	0,2	0,211	0,048	0,117	0,305	Benar

Tabel H Estimasi parameter GSTARX-SVR residual linier


Lokasi	Epsilon	Cost	Sigma	MAPE	MAPEp
1	0,00008	350,40	0,08	0,78608	1,38524
	0,00008	351,40	0,08	0,78602	1,38520
	0,00005	352,50	0,08	0,78600	1,38515
	0,00006	351,70	0,08	0,78598	1,38514
	0,00005	351,10	0,08	0,78599	1,38515
2	0,00005	354,50	0,06	0,40897	0,87257
	0,00006	354,70	0,06	0,40896	0,87255
	0,00008	353,60	0,06	0,40897	0,87260
	0,00007	354,50	0,06	0,40895	0,87257
	0,00007	353,60	0,06	0,40897	0,87260
3	0,00005	354,90	0,05	0,46824	1,15241
	0,00009	353,40	0,05	0,46821	1,15238
	0,00005	354,50	0,05	0,46823	1,15241
	0,00007	354,40	0,05	0,46823	1,15240
	0,00005	354,30	0,05	0,46823	1,15240

Tabel I Plot Aktual dan Ramalan Model GSTARX-SVR residual linier


Replikasi 1




Replikasi 2




Replikasi 3




Replikasi 4




Replikasi 5




Replikasi 6




Replikasi 7




Replikasi 8



Replikasi 9



Replikasi 10



Tabel J Peramalan data *out sample* studi simulasi residual linier

Bulan	Lokasi 1					Lokasi 2					Lokasi 3				
	Akt	VARX	VARX-SVR	GSTARX	GSTARX-SVR	Akt	VARX	VARX-SVR	GSTARX	GSTARX-SVR	Akt	VARX	VARX-SVR	GSTARX	GSTARX-SVR
Jan	102,19	103,01	102,81	103,27	102,81	113,99	113,71	114,38	113,86	114,38	110,10	109,46	109,22	109,75	109,22
Feb	103,83	105,22	104,35	105,35	104,35	115,95	117,09	117,22	117,00	117,22	113,02	113,89	114,27	113,84	114,27
Mar	106,74	107,48	107,08	108,51	107,08	116,65	118,37	118,38	119,36	118,38	115,57	116,07	116,11	116,87	116,11
Apr	103,07	104,01	104,06	105,77	104,06	114,51	115,45	114,74	117,38	114,74	112,51	112,76	112,91	114,16	112,91
Mei	134,33	135,04	134,59	137,23	134,59	147,94	148,04	147,50	150,30	147,50	144,55	145,16	145,27	146,87	145,27
Jun	145,60	145,39	144,89	147,75	144,89	164,58	165,25	165,31	167,62	165,31	153,98	154,44	154,13	156,41	154,13
Jul	93,52	93,25	93,54	95,64	93,54	104,20	103,55	103,16	106,16	103,16	100,98	100,88	100,54	102,93	100,54
Agust	88,98	90,66	90,47	92,55	90,47	101,86	101,23	101,26	103,17	101,26	97,47	98,43	98,12	100,04	98,12
Sep	84,35	86,36	85,17	88,70	85,17	96,84	97,22	98,06	99,33	98,06	95,30	96,42	95,85	98,39	95,85
Okt	89,90	89,57	88,35	92,66	88,35	100,41	100,65	101,12	103,58	101,12	98,30	97,93	97,43	100,49	97,43
Nop	92,58	93,51	93,28	96,01	93,28	103,49	103,96	103,45	106,59	103,45	102,15	101,65	101,53	103,69	101,53
Des	97,89	97,70	97,87	100,12	97,64	108,27	109,44	109,07	111,83	109,01	104,13	105,13	104,77	106,93	104,84

Tabel K Nilai RMSE *out sample* studi simulasi residual linier

Bulan	Lokasi 1				Lokasi 2				Lokasi 3			
	VARX	VARX-SVR	GSTARX	GSTARX-SVR	VARX	VARX-SVR	GSTARX	GSTARX-SVR	VARX	VARX-SVR	GSTARX	GSTARX-SVR
Jan	0,82	0,62	1,08	0,62	0,28	0,39	0,14	0,39	0,64	0,88	0,35	0,88
Feb	1,14	0,57	1,32	0,57	0,83	0,94	0,75	0,94	0,76	1,08	0,63	1,08
Mar	1,02	0,50	1,48	0,50	1,20	1,26	1,68	1,26	0,69	0,94	0,91	0,94
Apr	1,00	0,66	1,86	0,66	1,14	1,10	2,04	1,10	0,61	0,84	1,14	0,84
Mei	0,95	0,60	2,11	0,60	1,02	1,00	2,11	1,00	0,61	0,81	1,46	0,81
Jun	0,87	0,62	2,12	0,62	0,97	0,96	2,29	0,96	0,59	0,75	1,66	0,75
Jul	0,81	0,58	2,12	0,58	0,93	0,97	2,25	0,97	0,54	0,71	1,71	0,71
Agust	0,97	0,75	2,35	0,75	0,90	0,93	2,15	0,93	0,61	0,70	1,84	0,70
Sep	1,13	0,76	2,65	0,76	0,86	0,97	2,19	0,97	0,69	0,69	2,01	0,69
Okt	1,08	0,87	2,66	0,87	0,82	0,95	2,31	0,95	0,66	0,71	2,03	0,71
Nop	1,06	0,86	2,74	0,86	0,79	0,90	2,39	0,90	0,65	0,70	1,99	0,70
Des	1,02	0,82	2,70	0,83	0,83	0,89	2,51	0,89	0,68	0,70	2,07	0,70

Tabel L Kebaikan model studi simulasi residual linier

Repikasi	Metode Peramalan	RMSE						MAPE					
		<i>Training</i>			<i>Testing</i>			<i>Training</i>			<i>Testing</i>		
		Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
1	TSR	1,55518	1,46792	1,27555	2,34579	2,17168	1,82029	2,64440	2,13888	2,16268	2,15620	1,76300	1,53085
	VARX	0,87870	0,64131	0,68843	1,02012	0,83037	0,68475	1,45084	0,89143	1,16642	0,87758	0,61647	0,56775
	VARX-SVR	0,86221	0,62711	0,67273	0,82220	0,89372	0,69614	1,31381	0,81407	1,09766	0,68600	0,68156	0,59373
	GSTARX	0,88035	0,64890	0,69083	2,69847	2,50936	2,07187	1,44922	0,90494	1,16651	2,57600	2,03927	1,75522
	GSTARX-SVR	0,87537	0,63724	0,68747	0,82536	0,88951	0,70124	1,38524	0,87257	1,15241	0,70578	0,67705	0,59885
2	TSR	1,40324	1,26466	1,10299	1,15862	1,02277	0,81893	2,45501	1,85729	1,91350	0,77033	0,73750	0,62507
	VARX	0,87590	0,65283	0,64653	0,91387	0,64474	0,60944	1,47477	0,89626	1,12277	0,67979	0,40332	0,47002
	VARX-SVR	0,85455	0,63253	0,63257	1,01738	0,60423	0,62027	1,34174	0,79749	1,00070	0,82760	0,39378	0,42978
	GSTARX	0,87836	0,65988	0,65096	1,26238	1,11457	0,85325	1,47984	0,90297	1,12918	0,88676	0,76243	0,61817
	GSTARX-SVR	0,87770	0,65358	0,63978	1,00728	0,58586	0,62383	1,44035	0,86686	1,05447	0,82116	0,37943	0,43221
3	TSR	1,50234	1,38502	1,17751	1,12349	1,11190	0,80478	2,40608	1,90296	1,91383	0,84138	0,77608	0,63673
	VARX	0,88408	0,60020	0,64564	0,66780	0,56222	0,33071	1,45433	0,87714	1,15226	0,55021	0,41657	0,24744
	VARX-SVR	0,87126	0,58482	0,61817	0,80578	0,77398	0,34464	1,38547	0,79619	1,04237	0,63646	0,54322	0,27359
	GSTARX	0,88444	0,60187	0,64640	0,74021	0,66621	0,49026	1,45508	0,87960	1,14886	0,61882	0,50260	0,32841
	GSTARX-SVR	0,87182	0,59933	0,64359	0,80571	0,77799	0,34270	1,41288	0,84051	1,15292	0,63502	0,55457	0,27260
4	TSR	1,31329	1,24752	1,12837	1,75472	1,73987	1,13655	2,26898	1,92815	2,03364	1,33629	1,19177	0,79473
	VARX	0,85035	0,63484	0,70202	0,62404	0,67362	0,67180	1,39590	0,91373	1,19642	0,53206	0,50804	0,44279
	VARX-SVR	0,84264	0,61712	0,68487	0,67809	0,96025	0,70501	1,32169	0,83689	1,10475	0,60296	0,68062	0,47937
	GSTARX	0,85077	0,63584	0,70251	1,11240	1,16175	0,77126	1,39736	0,91780	1,19630	0,92722	0,82210	0,62758
	GSTARX-SVR	0,84611	0,62492	0,69362	0,67614	0,96114	0,69821	1,36550	0,88436	1,15462	0,60067	0,68846	0,46891
5	TSR	1,35946	1,23264	1,06346	1,61748	1,30160	1,03935	2,24811	1,73453	1,85251	1,19448	1,00216	0,84178
	VARX	0,82006	0,60501	0,64669	1,13645	0,73443	0,68021	1,35883	0,89835	1,18044	0,72717	0,51172	0,49911

Repikasi	Metode Peramalan	RMSE						MAPE					
		Training			Testing			Training			Testing		
		Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
	VARX-SVR	0,79524	0,58066	0,61728	1,36827	0,82755	0,62228	1,27374	0,82222	1,06614	1,01235	0,54229	0,48278
	GSTARX	0,82056	0,60572	0,64688	1,77653	1,03672	0,82633	1,35783	0,89955	1,18331	1,15956	0,71945	0,63216
	GSTARX-SVR	0,80024	0,60497	0,64193	1,37347	0,82473	0,61837	1,29798	0,89267	1,13696	1,04575	0,52684	0,46844
6	TSR	1,55511	1,40292	1,19378	2,06509	2,14258	1,75879	2,59938	2,07251	2,09469	1,62060	1,67930	1,42455
	VARX	0,84547	0,60164	0,62228	0,92234	0,61596	0,66760	1,41713	0,85923	1,09323	0,73313	0,41794	0,49379
	VARX-SVR	0,80710	0,57268	0,58497	0,98470	0,65974	0,68965	1,27151	0,73897	0,95297	0,76510	0,39677	0,47156
	GSTARX	0,84644	0,60268	0,62313	1,73170	1,81378	1,49010	1,42132	0,85842	1,09593	1,25144	1,39341	1,23462
	GSTARX-SVR	0,83588	0,59098	0,60902	0,98446	0,66407	0,69286	1,33686	0,80888	1,04266	0,76473	0,40023	0,47595
7	TSR	1,57815	1,46231	1,28153	1,60456	1,46155	1,54473	2,81580	2,31790	2,39767	1,32723	1,15555	1,20590
	VARX	0,88554	0,65974	0,69073	0,79431	0,72928	0,71324	1,44750	0,94589	1,22246	0,61144	0,53935	0,57936
	VARX-SVR	0,86072	0,63872	0,67980	1,09644	0,78753	0,71840	1,36392	0,86493	1,14770	0,95509	0,59618	0,56199
	GSTARX	0,88624	0,66099	0,69084	1,29905	1,13335	1,27191	1,44974	0,94832	1,22365	1,00647	0,86521	0,95992
	GSTARX-SVR	0,87460	0,64574	0,69537	1,08682	0,78961	0,69629	1,43183	0,90553	1,20907	0,94416	0,59781	0,54910
8	TSR	1,38468	1,21638	1,05556	1,05412	0,75571	0,56651	2,06219	1,60264	1,62861	0,78081	0,59631	0,42006
	VARX	0,83262	0,61024	0,60824	1,08359	0,52866	0,54004	1,33028	0,85321	1,01917	0,90322	0,39492	0,33694
	VARX-SVR	0,82507	0,59025	0,59585	1,26083	0,74374	0,65988	1,27211	0,75329	0,95157	0,98975	0,53403	0,45316
	GSTARX	0,83603	0,61196	0,60983	1,07228	0,78117	0,59510	1,33283	0,85624	1,01949	0,79128	0,61458	0,44609
	GSTARX-SVR	0,83704	0,60860	0,60037	1,24242	0,74666	0,66115	1,32508	0,83573	0,98417	0,98063	0,53549	0,45405
9	TSR	1,58842	1,48371	1,30777	1,12515	0,72191	0,75222	2,78619	2,20925	2,37947	0,78755	0,52557	0,51919
	VARX	0,83004	0,64344	0,69373	0,94080	0,44007	0,66846	1,35642	0,89889	1,17592	0,61689	0,31271	0,51550
	VARX-SVR	0,79227	0,59014	0,67614	1,18040	0,57527	0,78732	1,18778	0,76173	1,10587	0,86053	0,40672	0,58335
	GSTARX	0,83093	0,64372	0,69448	1,23691	0,80130	0,81567	1,35567	0,90041	1,17795	0,73039	0,50578	0,53386
	GSTARX-SVR	0,81253	0,63810	0,69271	1,18480	0,57538	0,76217	1,28110	0,88022	1,15191	0,86350	0,40699	0,57080

Repikasi	Metode Peramalan	RMSE						MAPE					
		<i>Training</i>			<i>Testing</i>			<i>Training</i>			<i>Testing</i>		
		Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
10	TSR	1,56267	1,42420	1,28600	1,25352	1,20256	0,94127	2,63227	2,09062	2,34342	1,15684	0,98032	0,69899
	VARX	0,86458	0,59526	0,68254	0,66181	0,50105	0,66937	1,47781	0,86582	1,21478	0,59518	0,31292	0,43288
	VARX-SVR	0,82843	0,57589	0,64801	0,60167	0,52811	0,75495	1,24748	0,77998	1,06858	0,51961	0,27477	0,48517
	GSTARX	0,86783	0,60348	0,68686	1,27849	1,22883	0,96071	1,48416	0,87522	1,23285	1,18310	1,00395	0,71890
	GSTARX-SVR	0,85137	0,59496	0,66755	0,60829	0,53079	0,75865	1,40421	0,82179	1,17476	0,53753	0,28524	0,49048
Rata-Rata	TSR	1,48025	1,35873	1,18725	1,51025	1,36321	1,11834	2,49184	1,98547	2,07200	1,19717	1,04076	0,86978
	VARX	0,85673	0,62445	0,66268	0,87651	0,62604	0,62356	1,41638	0,89000	1,15439	0,68267	0,44340	0,45856
	VARX-SVR	0,83395	0,60099	0,64104	0,98157	0,73541	0,65985	1,29793	0,79658	1,05383	0,78555	0,50499	0,48145
	GSTARX	0,85820	0,62750	0,66427	1,42084	1,22471	1,01465	1,41830	0,89435	1,15740	1,11310	0,92288	0,78549
	GSTARX-SVR	0,84827	0,61984	0,65714	0,97948	0,73457	0,65555	1,36810	0,86091	1,12139	0,78989	0,50521	0,47814

LAMPIRAN 2 Studi Simulasi Residual Non Linier

Tabel A Estimasi parameter model level satu dengan residual non linier

Lokasi	Parameter	OLS		GLS		Efisiensi (%)
		Estimasi	SE	Estimasi	SE	GLS
1	T	0,207	0,001	0,207	0,001	0,000
	S1	23,089	0,630	23,089	0,630	0,000
	S2	24,755	0,631	24,755	0,631	0,000
	S3	27,926	0,633	27,926	0,633	0,000
	S4	25,560	0,633	25,560	0,633	0,000
	S5	22,213	0,633	22,213	0,633	0,000
	S6	17,677	0,633	17,677	0,633	0,000
	S7	13,583	0,635	13,583	0,635	0,000
	S8	10,264	0,634	10,264	0,634	0,000
	S9	6,834	0,635	6,834	0,635	0,000
	S10	11,035	0,637	11,035	0,637	0,000
	S11	13,042	0,638	13,042	0,638	0,000
	S12	18,068	0,638	18,068	0,638	0,000
	M1t	31,653	1,222	31,653	1,222	0,000
	M2t	42,553	1,077	42,553	1,077	0,000
	M3t	46,083	1,143	46,083	1,143	0,000
	M4t	49,234	1,078	49,234	1,078	0,000
	M1t1	49,845	1,221	49,845	1,221	0,000
	M2t1	45,422	1,078	45,422	1,078	0,000
	M3t1	39,878	1,143	39,878	1,143	0,000
	M4t1	32,664	1,078	32,664	1,078	0,000
2	T	0,227	0,001	0,227	0,001	0,000
	S1	25,850	0,584	25,850	0,584	0,000
	S2	28,709	0,584	28,709	0,584	0,000
	S3	31,135	0,586	31,135	0,586	0,000
	S4	29,286	0,587	29,286	0,587	0,000
	S5	25,041	0,586	25,041	0,586	0,000
	S6	21,863	0,587	21,863	0,587	0,000
	S7	16,593	0,588	16,593	0,588	0,000
	S8	13,454	0,588	13,454	0,588	0,000
	S9	9,898	0,589	9,898	0,589	0,000
	S10	14,144	0,590	14,144	0,590	0,000
	S11	16,210	0,591	16,210	0,591	0,000
	S12	21,906	0,591	21,906	0,591	0,000
	M1t	44,851	1,132	44,851	1,132	0,000
	M2t	48,575	0,998	48,575	0,998	0,000
	M3t	54,385	1,059	54,385	1,059	0,000
	M4t	56,989	0,999	56,989	0,999	0,000

Lokasi	Parameter	OLS		GLS		Efisiensi (%)
		Estimasi	SE	Estimasi	SE	GLS
3	M1t1	59,112	1,132	59,112	1,132	0,000
	M2t1	53,883	0,998	53,883	0,998	0,000
	M3t1	45,060	1,059	45,060	1,059	0,000
	M4t1	35,123	0,999	35,123	0,999	0,000
	T	0,237	0,001	0,237	0,001	0,000
	S1	17,993	0,549	17,993	0,549	0,000
	S2	21,780	0,550	21,780	0,550	0,000
	S3	24,854	0,552	24,854	0,552	0,000
	S4	22,342	0,552	22,342	0,552	0,000
	S5	17,204	0,552	17,204	0,552	0,000
	S6	12,853	0,552	12,853	0,552	0,000
	S7	9,520	0,554	9,520	0,554	0,000
	S8	6,391	0,553	6,391	0,553	0,000
	S9	5,008	0,554	5,008	0,554	0,000
	S10	7,131	0,556	7,131	0,556	0,000
	S11	9,374	0,556	9,374	0,556	0,000
	S12	13,011	0,557	13,011	0,557	0,000
	M1t	36,794	1,066	36,794	1,066	0,000
	M2t	39,775	0,940	39,775	0,940	0,000
	M3t	46,289	0,997	46,289	0,997	0,000
	M4t	51,114	0,940	51,114	0,940	0,000
	M1t1	48,639	1,065	48,639	1,065	0,000
	M2t1	46,576	0,940	46,576	0,940	0,000
	M3t1	41,580	0,997	41,580	0,997	0,000
	M4t1	35,779	0,940	35,779	0,940	0,000

Tabel B Koefisien parameter model level satu TSR-GLS residual non linier

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
1	T	0,21	0,21	0,001	0,204	0,210	Benar
	S1	22	23,09	0,630	21,854	24,323	Benar
	S2	24	24,75	0,631	23,519	25,991	Benar
	S3	27	27,93	0,633	26,686	29,166	Benar
	S4	24	25,56	0,633	24,319	26,801	Benar
	S5	22	22,21	0,633	20,973	23,453	Benar
	S6	17	17,68	0,633	16,436	18,917	Benar
	S7	13	13,58	0,635	12,338	14,827	Benar
	S8	10	10,26	0,634	9,021	11,508	Benar
	S9	6	6,83	0,635	5,589	8,079	Benar
	S10	10	11,03	0,637	9,786	12,284	Benar
	S11	13	13,04	0,638	11,792	14,292	Benar
	S12	17	18,07	0,638	16,817	19,319	Benar
	M1t	32	31,65	1,222	29,258	34,047	Benar
	M2t	43	42,55	1,077	40,441	44,665	Benar
	M3t	47	46,08	1,143	43,843	48,322	Benar
	M4t	49	49,23	1,078	47,122	51,347	Benar
	M1t1	50	49,85	1,221	47,451	52,239	Benar
	M2t1	46	45,42	1,078	43,310	47,534	Benar
	M3t1	39	39,88	1,143	37,639	42,118	Benar
	M4t1	34	32,66	1,078	30,551	34,776	Benar
2	T	0,23	0,23	0,001	0,224	0,229	Benar
	S1	25	25,85	0,584	24,706	26,994	Benar
	S2	28	28,71	0,584	27,564	29,854	Benar
	S3	30	31,13	0,586	29,986	32,283	Benar
	S4	28	29,29	0,587	28,136	30,436	Benar
	S5	25	25,04	0,586	23,892	26,190	Benar
	S6	21	21,86	0,587	20,714	23,013	Benar
	S7	16	16,59	0,588	15,440	17,747	Benar
	S8	13	13,45	0,588	12,302	14,606	Benar
	S9	9	9,90	0,589	8,744	11,051	Benar
	S10	13	14,14	0,590	12,987	15,301	Benar
	S11	16	16,21	0,591	15,052	17,368	Benar
	S12	21	21,91	0,591	20,746	23,065	Benar
	M1t	45	44,85	1,132	42,632	47,069	Benar
	M2t	49	48,57	0,998	46,618	50,531	Benar
	M3t	55	54,38	1,059	52,310	56,460	Benar
	M4t	57	56,99	0,999	55,032	58,946	Benar
	M1t1	60	59,11	1,132	56,894	61,330	Benar
	M2t1	54	53,88	0,998	51,926	55,840	Benar
	M3t1	44	45,06	1,059	42,985	47,135	Benar

Lokasi	Parameter	Koefisien		SE	CI 95%		Keterangan
		Nilai sebenarnya	Estimasi		Batas bawah	Batas atas	
3	M4t1	36	35,12	0,999	33,166	37,080	Benar
	T	0,24	0,24	0,001	0,234	0,239	Benar
	S1	17	17,99	0,549	16,916	19,070	Benar
	S2	21	21,78	0,550	20,701	22,858	Benar
	S3	24	24,85	0,552	23,773	25,936	Benar
	S4	21	22,34	0,552	21,260	23,425	Benar
	S5	17	17,20	0,552	16,123	18,286	Benar
	S6	12	12,85	0,552	11,771	13,936	Benar
	S7	9	9,52	0,554	8,434	10,606	Benar
	S8	6	6,39	0,553	5,307	7,476	Benar
	S9	4	5,01	0,554	3,922	6,094	Benar
	S10	6	7,13	0,556	6,041	8,220	Benar
	S11	9	9,37	0,556	8,284	10,465	Benar
	S12	12	13,01	0,557	11,920	14,103	Benar
	M1t	37	36,79	1,066	34,705	38,883	Benar
	M2t	40	39,78	0,940	37,933	41,617	Benar
	M3t	47	46,29	0,997	44,336	48,243	Benar
	M4t	51	51,11	0,940	49,271	52,957	Benar
	M1t1	49	48,64	1,065	46,550	50,727	Benar
	M2t1	47	46,58	0,940	44,734	48,418	Benar
	M3t1	41	41,58	0,997	39,627	43,534	Benar
	M4t1	37	35,78	0,940	33,937	37,622	Benar

Tabel C Estimasi parameter model VAR di level dua residual non linier


Lokasi	Parameter	Estimasi	<i>Standard Error</i>	<i>t Value</i>	<i>P-Value</i>	Variabel
zresid11	AR1_1_1	0,035	0,135	0,26	0,7963	zresid11(t-1)
	AR1_1_2	0,124	0,125	0,99	0,3228	zresid21(t-1)
	AR1_1_3	0,168	0,195	0,86	0,3892	zresid31(t-1)
	AR2_1_1	0,088	0,135	0,66	0,5127	zresid11(t-2)
	AR2_1_2	-0,158	0,124	-1,27	0,2042	zresid21(t-2)
	AR2_1_3	0,472	0,195	2,43	0,0157	zresid31(t-2)
zresid21	AR1_2_1	-0,102	0,125	-0,81	0,4158	zresid11(t-1)
	AR1_2_2	0,229	0,116	1,97	0,0492	zresid21(t-1)
	AR1_2_3	0,183	0,181	1,01	0,3121	zresid31(t-1)
	AR2_2_1	-0,155	0,126	-1,23	0,2193	zresid11(t-2)
	AR2_2_2	0,082	0,116	0,71	0,4775	zresid21(t-2)
	AR2_2_3	0,458	0,181	2,53	0,0119	zresid31(t-2)
zresid31	AR1_3_1	-0,009	0,117	-0,08	0,9362	zresid11(t-1)
	AR1_3_2	0,106	0,109	0,98	0,328	zresid21(t-1)
	AR1_3_3	0,201	0,169	1,19	0,2353	zresid31(t-1)
	AR2_3_1	-0,084	0,117	-0,71	0,4769	zresid11(t-2)
	AR2_3_2	-0,157	0,108	-1,45	0,1478	zresid21(t-2)
	AR2_3_3	0,600	0,169	3,55	0,0004	zresid31(t-2)

Tabel D Estimasi parameter model VARX-SVR residual non linier


Lokasi	Epsilon	Cost	Sigma	Error	MAPE	MAPEp
1	0,00006	353,70	0,08	0,58022	0,552680	2,979492
	0,00007	351,10	0,09	0,45408	0,452594	2,979493
	0,00005	353,80	0,08	0,58014	0,552606	2,979493
	0,00006	351,60	0,08	0,58189	0,554146	2,979493
	0,00005	352,30	0,09	0,45308	0,451608	2,979494
2	0,00007	350,80	0,10	0,20879	0,227781	2,414975
	0,00005	354,60	0,09	0,29859	0,306768	2,414975
	0,00006	353,10	0,09	0,29989	0,307643	2,414976
	0,00006	351,50	0,10	0,20834	0,227383	2,414977
	0,00005	354,40	0,10	0,20647	0,225674	2,414977
3	0,00009	350,90	0,09	0,25332	0,354853	2,392226
	0,00007	352,10	0,09	0,25272	0,353857	2,392228
	0,00008	354,80	0,09	0,25137	0,351641	2,392229
	0,00007	350,80	0,05	0,78928	1,040188	2,392230
	0,00008	353,30	0,07	0,50000	0,632025	2,392230

Tabel E Plot Aktual dan Ramalan Model VARX-SVR residual non linier


Replikasi 1




Replikasi 2




Replikasi 3




Replikasi 4




Replikasi 5




Replikasi 6




Replikasi 7




Replikasi 8



Replikasi 9



Replikasi 10



Tabel F Estimasi parameter model GSTAR di level dua residual non linier


Lokasi	Parameter	OLS		GLS		Efisiensi (%)
		Estimasi	SE	Estimasi	SE	GLS
1	ϕ_{10}^1	0,054	0,118	0,134	0,049	0,582
	ϕ_{10}^2	0,238	0,118	0,236	0,049	0,581
	ϕ_{11}^1	0,136	0,135	0,091	0,062	0,537
	ϕ_{11}^2	0,068	0,136	0,069	0,063	0,537
2	ϕ_{20}^1	0,282	0,108	0,229	0,052	0,522
	ϕ_{20}^2	0,167	0,108	0,299	0,052	0,521
	ϕ_{21}^1	0,009	0,108	0,033	0,058	0,467
	ϕ_{21}^2	0,091	0,108	0,027	0,058	0,466
3	ϕ_{30}^1	0,192	0,167	0,108	0,057	0,656
	ϕ_{30}^2	0,608	0,167	0,238	0,057	0,657
	ϕ_{31}^1	0,050	0,157	0,090	0,060	0,619
	ϕ_{31}^2	-0,122	0,157	0,048	0,060	0,619

Tabel G Estimasi parameter GSTARX-SVR residual non linier


Lokasi	Epsilon	Cost	Sigma	Error	MAPE	MAPEp
1	0,00006	350,00	0,05	2,00564	1,924478	2,929759
	0,00007	350,00	0,05	2,00564	1,924456	2,929763
	0,00009	350,00	0,05	2,00565	1,924418	2,929767
	0,00008	350,00	0,05	2,00568	1,924461	2,929768
	0,00005	350,00	0,05	2,00568	1,924448	2,929770
2	0,00008	354,20	0,05	1,79182	1,513066	2,408432
	0,00007	355,00	0,05	1,79156	1,512660	2,408432
	0,00009	355,00	0,05	1,79156	1,512682	2,408439
	0,00009	353,40	0,05	1,79197	1,513447	2,408471
	0,00008	352,80	0,05	1,79212	1,513795	2,408484
3	0,00006	350,00	0,05	1,49355	1,979865	2,303094
	0,00005	350,00	0,05	1,49355	1,979878	2,303095
	0,00009	350,20	0,05	1,49342	1,979872	2,303123
	0,00008	350,00	0,05	1,49354	1,979973	2,303124
	0,00009	350,00	0,05	1,49354	1,979899	2,303126

Tabel H Plot Aktual dan Ramalan Model GSTARX-SVR residual non linier


Replikasi 1




Replikasi 2




Replikasi 3




Replikasi 4




Replikasi 5




Replikasi 6




Replikasi 7




Replikasi 8



Replikasi 9



Replikasi 10



Tabel I Peramalan data *out sample* studi simulasi residual non linier

Bulan	Lokasi 1					Lokasi 2					Lokasi 3				
	Akt	VARX	VARX-SVR	GSTARX	GSTARX-SVR	Akt	VARX	VARX-SVR	GSTARX	GSTARX-SVR	Akt	VARX	VARX-SVR	GSTARX	GSTARX-SVR
Jan	102,18	105,53	107,62	105,30	107,62	113,84	115,59	118,60	115,42	118,60	110,31	111,50	113,19	111,32	113,19
Feb	102,80	104,88	104,06	107,20	104,06	117,17	116,81	116,92	118,79	116,92	114,37	113,67	114,34	115,25	114,34
Mar	106,50	108,29	106,18	109,71	106,18	119,04	119,79	119,83	120,45	119,83	117,54	117,13	117,68	117,87	117,68
Apr	102,39	106,27	104,34	107,30	104,34	116,32	118,00	117,42	118,63	117,42	114,32	114,90	115,26	115,35	115,26
Mei	134,70	135,28	131,92	136,42	131,92	147,53	148,86	147,42	149,33	147,42	145,55	145,50	145,20	145,90	145,20
Jun	145,49	147,96	146,94	148,46	146,94	164,40	167,52	166,44	168,06	166,44	153,01	156,68	156,77	156,94	156,77
Jul	93,31	93,17	92,37	95,13	92,37	105,14	103,82	102,37	105,83	102,37	101,54	100,64	98,80	102,56	98,80
Agust	85,29	91,18	90,20	91,88	90,20	98,77	102,42	102,23	102,80	102,23	94,30	99,05	98,65	99,55	98,65
Sep	86,65	85,98	82,07	88,54	82,07	98,79	97,49	95,44	99,36	95,44	97,23	96,20	93,15	98,30	93,15
Okt	88,03	92,37	91,05	92,87	91,05	99,17	103,53	103,26	103,76	103,26	96,58	100,22	99,59	100,59	99,59
Nop	94,99	93,37	90,24	95,02	90,24	105,96	104,45	101,46	105,99	101,46	103,98	101,68	99,06	103,02	99,06
Des	96,87	100,62	100,22	100,20	99,64	107,80	112,28	111,88	111,87	111,80	104,64	107,36	107,85	106,85	106,73

Tabel J Nilai RMSE *out sample* studi simulasi residual non linier

Bulan	Lokasi 1				Lokasi 2				Lokasi 3			
	VARX	VARX-SVR	GSTARX	GSTARX-SVR	VARX	VARX-SVR	GSTARX	GSTARX-SVR	VARX	VARX-SVR	GSTARX	GSTARX-SVR
Jan	3,35	5,44	3,12	5,44	1,75	4,76	1,58	4,76	1,19	2,87	1,00	2,87
Feb	2,78	3,95	3,81	3,95	1,26	3,37	1,60	3,37	0,97	2,03	0,95	2,03
Mar	2,50	3,23	3,62	3,23	1,12	2,79	1,54	2,79	0,83	1,66	0,80	1,66
Apr	2,90	2,96	3,98	2,96	1,28	2,48	1,76	2,48	0,77	1,51	0,86	1,51
Mei	2,61	2,93	3,64	2,93	1,29	2,22	1,77	2,22	0,69	1,36	0,79	1,36
Jun	2,59	2,74	3,54	2,74	1,73	2,19	2,20	2,19	1,63	1,98	1,76	1,98
Jul	2,40	2,56	3,35	2,56	1,68	2,28	2,05	2,28	1,55	2,10	1,67	2,10
Agust	3,06	2,96	3,90	2,96	2,03	2,46	2,39	2,46	2,22	2,50	2,43	2,50
Sep	2,89	3,18	3,73	3,18	1,97	2,57	2,26	2,57	2,12	2,72	2,32	2,72
Okt	3,07	3,16	3,86	3,16	2,32	2,76	2,59	2,76	2,32	2,75	2,54	2,75
Nop	2,97	3,34	3,68	3,34	2,26	2,96	2,47	2,96	2,31	3,01	2,44	3,01
Des	3,04	3,34	3,65	3,29	2,52	3,07	2,64	3,06	2,35	3,03	2,42	2,95

Tabel K Kebaikan model studi simulasi residual non linier

Repikasi	Metode Peramalan	RMSE						MAPE					
		<i>Training</i>			<i>Testing</i>			<i>Training</i>			<i>Testing</i>		
		Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
1	TSR	3,0873	2,8606	2,6933	2,8259	2,2138	2,2247	5,7901	4,4080	5,9465	2,3476	1,4052	1,5982
	VARX	2,5741	2,3948	2,2382	3,0394	2,5176	2,3496	4,6491	3,6809	4,7352	2,6017	1,9120	1,7111
	VARX-SVR	0,7649	0,4640	0,5094	3,3391	3,0705	3,0300	0,5527	0,2278	0,3549	2,9795	2,4150	2,3922
	GSTARX	2,5927	2,4182	2,2560	3,6526	2,6412	2,4187	4,7172	3,7379	4,8396	3,2743	1,9282	1,7117
	GSTARX-SVR	1,4144	1,3120	1,2206	3,2945	3,0613	2,9473	1,9245	1,5131	1,9799	2,9298	2,4084	2,3031
2	TSR	2,9792	2,7172	2,5658	3,0702	2,6866	2,7956	5,2085	3,9768	4,5100	2,6071	2,0113	2,1694
	VARX	2,4898	2,0935	2,0352	3,0796	2,6245	2,8262	4,2422	2,9705	3,5151	2,6891	1,9728	2,2999
	VARX-SVR	0,6235	0,7774	0,3708	2,8322	2,5145	2,5117	0,3268	0,4649	0,1669	1,9639	1,8070	1,7522
	GSTARX	2,5006	2,1152	2,0491	3,0667	2,6104	2,8171	4,2796	3,0151	3,6033	2,6755	1,9555	2,2867
	GSTARX-SVR	0,9773	1,1024	1,1222	2,8322	2,5379	2,4766	1,1452	1,1601	1,6326	1,9639	1,8232	1,7189
3	TSR	3,0425	2,8761	2,6469	1,7000	1,5324	1,3268	5,2252	4,2382	4,8298	1,2519	1,2025	0,9658
	VARX	2,5160	2,1967	2,1090	2,7635	1,2965	2,2574	4,5714	3,3767	4,1913	2,1730	0,9146	1,8969
	VARX-SVR	0,7211	0,6696	0,3979	2,2338	2,0127	1,8214	0,4007	0,3928	0,1569	1,5828	1,1392	1,1139
	GSTARX	2,5284	2,2070	2,1216	2,6478	1,2695	2,1403	4,5917	3,3898	4,1859	2,0741	0,9098	1,7954
	GSTARX-SVR	1,3881	1,0299	1,0292	2,2132	2,0127	1,8031	1,6865	0,9339	1,2639	1,5342	1,1392	1,0474
4	TSR	2,9289	2,7067	2,5532	2,9274	2,9508	2,6836	5,0633	4,0832	4,7064	2,3377	2,1561	1,7649
	VARX	2,3610	2,1393	2,0241	2,7589	2,7753	2,2675	4,1527	3,2912	3,6989	2,2001	2,0530	1,5538
	VARX-SVR	0,8363	0,6130	0,6601	3,4611	3,2402	2,9732	0,7028	0,4700	0,5920	3,0246	2,1735	2,0844
	GSTARX	2,3822	2,1579	2,0437	2,7335	2,8060	2,3447	4,2552	3,3447	3,7265	2,1707	2,0849	1,5763
	GSTARX-SVR	1,1710	1,0700	0,9688	3,3018	3,2301	2,8699	1,4792	1,0920	1,0800	2,8897	2,1666	1,9867
5	TSR	2,9391	2,7738	2,5487	3,6142	3,1911	2,4488	5,2441	4,2682	4,7713	3,1157	2,5709	1,9898
	VARX	2,3642	2,2250	2,0671	3,6521	3,0823	2,4267	3,9602	3,1670	3,5430	3,2540	2,4405	1,9755

Repikasi	Metode Peramalan	RMSE						MAPE					
		Training			Testing			Training			Testing		
		Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
	VARX-SVR	0,3755	0,6276	0,6144	2,2747	2,0017	1,1696	0,1522	0,3360	0,5094	1,6413	1,4832	0,8113
	GSTARX	2,3860	2,2644	2,0930	3,8791	3,2869	2,5264	3,9567	3,1983	3,6032	3,4980	2,6523	2,0897
	GSTARX-SVR	1,1160	1,0529	0,9970	2,1856	2,0017	1,2960	1,2459	0,9599	1,3153	1,4863	1,4832	0,9576
	TSR	2,8776	2,6931	2,4888	3,1744	3,0671	2,7311	4,7692	3,9040	4,4341	2,2770	2,1044	1,8205
	VARX	2,4630	2,1615	2,0442	3,1041	2,7520	2,5212	4,1637	3,1549	3,6994	2,2426	1,8314	1,6367
6	VARX-SVR	0,9914	0,7550	0,8091	2,9431	2,4706	2,4865	1,0054	0,5704	0,7944	2,0727	1,6998	1,6208
	GSTARX	2,4757	2,1721	2,0538	3,0810	2,7150	2,5006	4,2029	3,1785	3,7293	2,2187	1,8102	1,6301
	GSTARX-SVR	1,2294	1,2945	1,3135	2,9431	2,5080	2,4864	1,3672	1,5060	1,8876	2,0727	1,7435	1,6204
	TSR	3,1470	2,8316	2,6720	3,1645	3,1480	2,4897	5,3217	4,1071	4,6714	2,3071	2,0832	1,8072
	VARX	2,5490	2,2208	2,1394	3,2316	3,2181	2,5236	4,2225	3,1683	3,7180	2,4860	2,2276	1,8963
7	VARX-SVR	0,9972	0,5345	0,4821	4,1278	3,9902	3,1009	0,6900	0,1379	0,1768	3,6380	3,0481	2,3836
	GSTARX	2,5717	2,2385	2,1597	3,2042	3,1929	2,5039	4,2421	3,1923	3,7446	2,4425	2,1915	1,8623
	GSTARX-SVR	0,9972	0,5345	0,4821	4,1278	3,9902	3,1009	0,6900	0,1379	0,1768	3,6380	3,0481	2,3836
	TSR	2,9051	2,6637	2,4647	4,2036	4,0202	3,9381	4,9913	4,0311	4,5386	3,7110	3,1046	3,2253
	VARX	2,4494	2,2189	2,0110	4,2288	4,0449	3,9704	4,2695	3,3813	3,6793	3,7032	3,1121	3,2161
8	VARX-SVR	0,8961	0,8550	0,4573	2,5559	2,6026	2,1247	0,5889	0,5765	0,2164	2,0116	1,9051	1,5347
	GSTARX	2,4783	2,2465	2,0352	4,2265	4,0409	3,9655	4,3917	3,4388	3,7823	3,7086	3,1108	3,2176
	GSTARX-SVR	1,3698	1,2693	1,3162	2,5559	2,6035	2,1808	1,4070	1,2521	1,8976	2,0116	1,9118	1,6289
	TSR	3,0204	2,8282	2,6236	3,9079	3,1354	3,0818	4,9055	4,0644	4,4159	2,8610	2,1866	1,9091
	VARX	2,4759	2,2446	2,0735	3,9890	3,2020	3,1247	3,8860	3,1696	3,3885	2,9936	2,3407	2,0140
9	VARX-SVR	0,8173	0,7875	0,7958	3,8168	3,0221	3,1091	0,4684	0,4143	0,4933	2,9003	2,1254	2,3038
	GSTARX	2,4913	2,2590	2,0865	4,0479	3,2555	3,1729	3,9781	3,2387	3,4812	3,0656	2,3964	2,0648
	GSTARX-SVR	1,2715	0,9914	1,2001	3,8118	3,0724	3,1091	1,2700	0,8295	1,3907	2,8969	2,1906	2,3038

Repikasi	Metode Peramalan	RMSE						MAPE					
		<i>Training</i>			<i>Testing</i>			<i>Training</i>			<i>Testing</i>		
		Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
10	TSR	2,9913	2,7357	2,5458	3,4873	3,2956	2,8598	5,0784	4,0018	4,4856	2,8954	2,3440	2,2121
	VARX	2,4378	2,0948	1,9706	3,7120	3,5259	3,0834	4,0936	3,0474	3,5101	3,1148	2,5922	2,4262
	VARX-SVR	0,4118	0,4545	0,3529	2,8071	3,0300	1,8688	0,0898	0,1351	0,0976	2,4926	2,4685	1,4205
	GSTARX	2,4795	2,1336	2,0066	3,7846	3,6055	3,1710	4,0795	3,0376	3,4315	3,1893	2,6813	2,5033
	GSTARX-SVR	1,2260	1,2082	1,1254	2,9443	3,0306	1,8688	1,1934	0,9298	1,1807	2,6119	2,4685	1,4205
Rata-Rata	TSR	2,9918	2,7687	2,5803	3,2075	2,9241	2,6580	5,1597	4,1083	4,7310	2,5711	2,1169	1,9462
	VARX	2,4680	2,1990	2,0712	3,3559	2,9039	2,7351	4,2211	3,2408	3,7679	2,7458	2,1397	2,0626
	VARX-SVR	0,7435	0,6538	0,5450	3,0392	2,7955	2,4196	0,4978	0,3726	0,3558	2,4307	2,0265	1,7417
	GSTARX	2,4886	2,2212	2,0905	3,4324	2,9424	2,7561	4,2695	3,2772	3,8128	2,8317	2,1721	2,0738
	GSTARX-SVR	1,2161	1,0865	1,0775	3,0210	2,8048	2,4139	1,3409	1,0314	1,3805	2,4035	2,0383	1,7371

LAMPIRAN 3 Studi skenario data *inflow* dan *outflow*

Tabel A Statistika deskriptif data *inflow* dan *outflow*

a. KBI Bandung

Data	Bulan	Rata-rata	Standar deviasi	Minimum	Maksimum
<i>Inflow</i>	Januari	1406,076	448,972	609,325	2535,071
	Pebruari	1742,784	658,030	1389,010	3722,034
	Maret	1762,524	492,592	1285,316	3128,025
	April	1933,357	510,947	532,546	2599,621
	Mei	531,741	614,085	165,400	1960,455
	Juni	918,686	957,722	338,237	3688,651
	Juli	1187,415	923,849	543,270	3498,712
	Agustus	1539,136	842,058	534,267	3067,799
	September	2290,647	1490,111	548,981	6508,440
	Oktober	3453,802	713,859	2603,695	4671,748
	Nopember	4160,198	1409,497	3036,629	8238,152
	Desember	4662,229	1802,854	2256,372	9574,568
<i>Outflow</i>	Januari	978,417	343,049	516,421	1885,213
	Pebruari	1177,109	336,474	719,836	1828,284
	Maret	1290,157	590,983	701,455	2809,701
	April	1364,307	414,176	949,598	2262,401
	Mei	359,775	449,363	89,161	1307,242
	Juni	504,013	643,500	34,888	2234,565
	Juli	489,974	532,264	23,188	1831,575
	Agustus	829,849	851,309	114,949	2997,460
	September	1322,226	1459,850	107,769	5369,890
	Oktober	1900,289	1238,012	508,885	5008,684
	Nopember	2190,035	1088,837	754,467	5001,526
	Desember	2423,918	1756,829	836,941	7379,620

b. KBI Tasikmalaya

Data	Bulan	Rata-rata	Standar deviasi	Minimum	Maksimum
<i>Inflow</i>	Januari	474,726	151,967	320,336	909,477
	Pebruari	563,753	104,733	491,951	877,316
	Maret	648,853	154,274	549,319	1086,061
	April	705,232	166,549	272,081	943,279
	Mei	248,243	130,074	66,862	545,631
	Juni	237,617	80,471	104,823	383,870
	Juli	207,572	61,504	153,552	343,282
	Agustus	277,558	141,967	159,348	558,937

Data	Bulan	Rata-rata	Standar deviasi	Minimum	Maksimum
	September	402,073	264,704	123,958	1158,441
	Oktober	553,666	162,484	390,429	900,880
	Nopember	676,898	198,573	409,561	1192,571
	Desember	618,445	275,104	433,469	1399,145
<i>Outflow</i>	Januari	122,228	58,993	38,750	261,371
	Pebruari	174,132	79,225	85,822	308,298
	Maret	196,928	111,419	81,503	472,501
	April	258,639	99,634	150,028	452,803
	Mei	15,089	17,254	2,605	55,036
	Juni	36,888	78,991	4,243	280,790
	Juli	28,015	33,286	5,247	114,927
	Agustus	110,652	162,541	7,284	581,829
	September	136,944	138,288	6,432	473,259
	Oktober	201,580	169,220	29,870	605,514
	Nopember	329,524	150,911	137,410	633,861
	Desember	434,317	274,709	204,953	1225,181

c. KBI Cirebon

Data	Bulan	Rata-rata	Standar deviasi	Minimum	Maksimum
<i>Inflow</i>	Januari	876,703	272,55862	534,659	1667,229
	Pebruari	906,812	140,67648	776,700	1318,009
	Maret	996,261	248,07287	802,480	1732,788
	April	918,738	269,32323	260,663	1386,540
	Mei	406,247	169,97244	211,877	789,792
	Juni	522,901	180,12781	336,734	1011,176
	Juli	441,416	158,5863	231,206	847,391
	Agustus	644,007	282,99961	392,347	1305,769
	September	819,364	413,12332	264,259	1914,071
	Oktober	1064,295	245,43347	744,046	1475,278
	Nopember	1224,322	388,13698	811,513	2173,658
	Desember	1274,301	424,29536	832,317	2344,049
<i>Outflow</i>	Januari	290,502	114,667	106,755	558,273
	Pebruari	326,113	124,856	180,740	525,788
	Maret	367,289	199,244	162,762	905,395
	April	258,610	137,114	73,191	472,551
	Mei	62,738	115,085	2,317	405,466
	Juni	128,200	181,099	3,031	610,267
	Juli	122,239	134,666	5,771	367,719
	Agustus	247,695	183,405	7,852	609,084
	September	274,368	268,778	10,437	1018,288

Data	Bulan	Rata-rata	Standar deviasi	Minimum	Maksimum
	Oktober	476,296	308,292	134,197	1246,529
	Nopember	498,549	271,076	218,904	1130,654
	Desember	546,422	369,211	207,420	1612,191

Tabel B Estimasi parameter model level satu data *outflow* dan *inflow*

Studi Skenario	Lokasi	Parameter	DF	Estimasi Parameter	Standard Error	t Value	P-Value
<i>Outflow</i>	KBI Bandung	t	1	19,68	2,34	8,40	<.0001
		D1t	1	-1394,99	173,94	-8,02	<.0001
		D2t	1	-3263,84	958,25	-3,41	0,00
		tD2t	1	20,04	8,63	2,32	0,02
		S3	1	295,21	120,37	2,45	0,02
		S4	1	351,61	120,60	2,92	0,00
		S5	1	315,21	120,87	2,61	0,01
		S6	1	609,57	162,68	3,75	0,00
		S7	1	687,52	163,56	4,20	<.0001
		S8	1	314,56	124,93	2,52	0,01
		S12	1	1239,59	165,62	7,48	<.0001
		M2t	1	1104,46	263,74	4,19	<.0001
		M3t	1	2490,87	370,45	6,72	<.0001
		M4t	1	2404,38	302,54	7,95	<.0001
		M1t1	1	2205,91	365,11	6,04	<.0001
		M2t1	1	1252,35	264,04	4,74	<.0001
	KBI Tasikmalaya	t	1	4,39	0,37	11,73	<.0001
		D1t	1	-318,47	28,43	-11,20	<.0001
		D2t	1	-809,33	151,72	-5,33	<.0001
		tD2t	1	4,22	1,37	3,09	0,00
		S6	1	71,73	25,53	2,81	0,01
		S7	1	70,50	25,67	2,75	0,01
		S12	1	141,92	25,97	5,46	<.0001
		M2t	1	166,78	41,58	4,01	0,00
		M3t	1	247,12	58,09	4,25	<.0001
		M4t	1	269,73	47,67	5,66	<.0001
		M1t1	1	309,83	57,81	5,36	<.0001
		M2t1	1	136,25	41,64	3,27	0,00
	KBI Cirebon	D1t	1	-578,59	76,05	-7,61	<.0001
		D2t	1	-995,16	230,96	-4,31	<.0001
		tD1t	1	6,09	0,96	6,35	<.0001
		tD2t	1	9,95	2,01	4,96	<.0001
		S1	1	129,15	28,26	4,57	<.0001
		S2	1	130,19	28,27	4,61	<.0001
		S3	1	207,52	32,61	6,36	<.0001

Studi Skenario	Lokasi	Parameter	DF	Estimasi Parameter	Standard Error	t Value	P-Value
<i>Inflow</i>		S4	1	294,81	32,61	9,04	<.0001
		S5	1	207,44	32,62	6,36	<.0001
		S6	1	357,31	39,02	9,16	<.0001
		S7	1	298,43	39,31	7,59	<.0001
		S8	1	217,48	34,55	6,30	<.0001
		S9	1	148,07	30,33	4,88	<.0001
		S10	1	180,88	30,50	5,93	<.0001
		S11	1	160,03	29,58	5,41	<.0001
		S12	1	353,99	39,11	9,05	<.0001
		M2t	1	354,98	64,06	5,54	<.0001
		M3t	1	579,64	89,99	6,44	<.0001
		M4t	1	483,53	73,71	6,56	<.0001
		M1t1	1	672,69	89,20	7,54	<.0001
		M2t1	1	309,84	64,04	4,84	<.0001
	KBI Bandung	D1t	1	-2770,18	528,68	-5,24	<.0001
		D2t	1	-7851,15	1268,15	-6,19	<.0001
		tD1t	1	29,63	7,05	4,20	<.0001
		tD2t	1	82,83	11,01	7,52	<.0001
		S1	1	2210,16	216,66	10,20	<.0001
		S2	1	1434,63	216,31	6,63	<.0001
		S3	1	1592,82	216,04	7,37	<.0001
		S4	1	1386,52	215,85	6,42	<.0001
		S5	1	1414,82	215,72	6,56	<.0001
		S6	1	1271,12	215,68	5,89	<.0001
		S7	1	1606,63	215,70	7,45	<.0001
		S8	1	1857,66	217,67	8,53	<.0001
		S9	1	1681,32	224,89	7,48	<.0001
		S10	1	1561,64	226,10	6,91	<.0001
		S11	1	1520,18	229,48	6,62	<.0001
		S12	1	1004,55	221,89	4,53	<.0001
		M3t2	1	871,77	376,49	2,32	0,02
		M4t2	1	2196,88	411,97	5,33	<.0001
		M1t	1	2215,41	499,32	4,44	<.0001
		M2t	1	1359,57	353,76	3,84	0,00
	KBI Tasikmalaya	t	1	5,56	0,62	8,97	<.0001
		D1t	1	-279,13	87,32	-3,20	0,00
		D2t	1	-1257,51	207,14	-6,07	<.0001
		tD1t	1	-4,55	1,30	-3,50	0,00
		tD2t	1	6,23	1,89	3,29	0,00
		S1	1	471,98	37,93	12,44	<.0001
		S2	1	394,63	37,97	10,39	<.0001
		S3	1	431,05	38,01	11,34	<.0001
		S4	1	395,66	38,07	10,39	<.0001

Studi Skenario	Lokasi	Parameter	DF	Estimasi Parameter	Standard Error	t Value	P-Value
		S5	1	409,12	38,14	10,73	<.0001
		S6	1	394,99	38,23	10,33	<.0001
		S7	1	477,08	38,33	12,45	<.0001
		S8	1	476,76	38,75	12,30	<.0001
		S9	1	472,99	39,56	11,96	<.0001
		S10	1	457,66	39,77	11,51	<.0001
		S11	1	444,30	40,66	10,93	<.0001
		S12	1	324,38	39,68	8,17	<.0001
		M4t2	1	475,67	67,14	7,08	<.0001
		M1t	1	290,91	81,38	3,57	0,00
		M2t	1	324,10	57,57	5,63	<.0001
	KBI Cirebon	D1t	1	-847,73	154,80	-5,48	<.0001
		D2t	1	-1894,66	371,44	-5,10	<.0001
		tD1t	1	6,23	2,06	3,02	0,00
		tD2t	1	17,72	3,23	5,49	<.0001
		S1	1	1016,34	63,44	16,02	<.0001
		S2	1	806,24	63,34	12,73	<.0001
		S3	1	817,07	63,26	12,92	<.0001
		S4	1	826,19	63,20	13,07	<.0001
		S5	1	833,60	63,17	13,20	<.0001
		S6	1	819,78	63,15	12,98	<.0001
		S7	1	953,71	63,16	15,10	<.0001
		S8	1	911,44	63,74	14,30	<.0001
		S9	1	850,97	65,23	13,05	<.0001
		S10	1	901,05	65,56	13,74	<.0001
		S11	1	893,12	67,21	13,29	<.0001
		S12	1	762,69	64,97	11,74	<.0001
		M4t2	1	831,84	120,62	6,90	<.0001
		M1t	1	680,74	146,15	4,66	<.0001
		M2t	1	468,89	103,42	4,53	<.0001

Tabel C Estimasi parameter model VAR di level dua data *outflow* dan *inflow*

Studi Skenario	Lokasi	Parameter	Estimasi	Standard Error	t Value	P-Value	Variabel
<i>Outflow</i>	KBI Bandung	AR1_1_1	0,140	0,152	0,920	0,359	zresid11(t-1)
		AR1_1_2	-1,379	0,802	-1,720	0,088	zresid21(t-1)
		AR1_1_3	-0,097	0,597	-0,160	0,871	zresid31(t-1)
	KBI Tasikmalaya	AR1_2_1	0,009	0,024	0,380	0,705	zresid11(t-1)
		AR1_2_2	0,122	0,129	0,950	0,346	zresid21(t-1)
		AR1_2_3	-0,043	0,096	-0,450	0,654	zresid31(t-1)
	KBI Cirebon	AR1_3_1	0,017	0,036	0,470	0,637	zresid11(t-1)
		AR1_3_2*	-0,519	0,189	-2,750	0,007	zresid21(t-1)
		AR1_3_3*	0,278	0,140	1,980	0,050	zresid31(t-1)
<i>Inflow</i>	KBI Bandung	AR1_1_1	-0,122	0,119	-1,030	0,306	zresid12(t-1)
		AR1_1_2	-0,713	1,011	-0,700	0,482	zresid22(t-1)
		AR1_1_3	0,549	0,605	0,910	0,366	zresid32(t-1)
	KBI Tasikmalaya	AR1_2_1	0,001	0,019	0,050	0,963	zresid12(t-1)
		AR1_2_2	0,056	0,165	0,340	0,735	zresid22(t-1)
		AR1_2_3	0,013	0,098	0,130	0,896	zresid32(t-1)
	KBI Cirebon	AR1_3_1	-0,058	0,034	-1,690	0,093	zresid12(t-1)
		AR1_3_2	-0,096	0,292	-0,330	0,743	zresid22(t-1)
		AR1_3_3	0,300	0,175	1,720	0,088	zresid32(t-1)

(*) : Parameter signifikan

Tabel D Estimasi parameter model VARX-SVR data *outflow* dan *inflow*

KBI Bandung									
<i>Outflow</i>					<i>Inflow</i>				
Epsilon	Cost	Sigma	MAPE	MAPEp	Epsilon	Cost	Sigma	MAPE	MAPEp
0,00006	351,5	0,08	16,40581	71,82363	0,00005	355,00	0,10	15,25300	33,40406
0,00009	352,5	0,09	16,31273	71,82363	0,00006	355,00	0,10	15,25300	33,40406
0,00008	352,5	0,09	16,31272	71,82363	0,00007	355,00	0,10	15,25300	33,40406
0,00005	352,5	0,1	16,31273	71,82363	0,00008	355,00	0,10	15,25300	33,40406
0,00007	355	0,08	16,07992	71,82363	0,00009	355,00	0,10	15,25300	33,40406
KBI Tasikmalaya									
0,00008	351,5	0,09	0,00082	38,369195	0,00005	350,00	0,05	0,00005	28,51421
0,00008	353,9	0,08	0,00087	38,369195	0,00006	350,00	0,05	0,00004	28,51421
0,00005	354,6	0,07	0,00055	38,369196	0,00007	350,00	0,05	0,00004	28,51421
0,00008	351,9	0,1	0,00116	38,369196	0,00008	350,00	0,05	0,00005	28,51421
0,00009	351,1	0,08	0,00088	38,369196	0,00009	350,00	0,05	0,00005	28,51421
KBI Cirebon									
0,00009	350	0,1	0,00082	56,75073	0,00007	354,30	0,06	1,49124	22,29139
0,00009	350,1	0,1	0,00082	56,75073	0,00005	354,30	0,06	1,49124	22,29139
0,00009	350,2	0,1	0,00082	56,75073	0,00005	353,40	0,10	1,49964	22,29139
0,00009	350,3	0,1	0,00082	56,75073	0,00006	353,40	0,10	1,49964	22,29139
0,00009	350,4	0,1	0,00082	56,75073	0,00006	350,70	0,06	1,52496	22,29139

Tabel E Estimasi parameter model GSTAR di level dua data *outflow* dan *inflow*

Studi Skenario	Bobot	Lokasi	Variabel	DF	Estimasi Parameter	Standard Error	t Value	P-Value
<i>Outflow</i>	Seragam	KBI	lagresi11	1	-0,067	0,111	-0,600	0,547
		Bandung	w11	1	0,079	0,554	0,140	0,887
		KBI	lagresi21	1	0,330	0,087	3,790	0,000
		Tasikmalaya	w21	1	-0,043	0,028	-1,540	0,125
		KBI	lagresi31	1	0,288	0,095	3,010	0,003
		Cirebon	w31	1	-0,090	0,047	-1,910	0,059
	Invers	KBI	lagresi11	1	-0,067	0,111	-0,610	0,543
		Bandung	w11	1	0,056	0,542	0,100	0,917
		KBI	lagresi21	1	0,327	0,086	3,780	0,000
		Tasikmalaya	w21	1	-0,043	0,028	-1,560	0,122
		KBI	lagresi31	1	0,290	0,096	3,020	0,003
		Cirebon	w31	1	-0,100	0,051	-1,970	0,051
	NIKSP	KBI	lagresi11	1	0,014	0,097	0,150	0,883
		Bandung	w11	1	-0,239	0,592	-0,400	0,687
		KBI	lagresi21	1	0,301	0,080	3,770	0,000
		Tasikmalaya	w21	1	-0,077	0,060	-1,300	0,197
		KBI	lagresi31	1	0,238	0,103	2,310	0,022
		Cirebon	w31	1	-0,060	0,042	-1,400	0,163
<i>Inflow</i>	Seragam	KBI	lagresi12	1	-0,110	0,104	-1,060	0,292
		Bandung	w12	1	0,178	0,450	0,400	0,693
		KBI	lagresi22	1	0,075	0,074	1,020	0,310
		Tasikmalaya	w22	1	0,003	0,026	0,100	0,919
		KBI	lagresi32	1	0,270	0,077	3,520	0,001
		Cirebon	w32	1	-0,112	0,050	-2,220	0,028
	Invers	KBI	lagresi12	1	-0,109	0,103	-1,060	0,293
		Bandung	w12	1	0,177	0,438	0,410	0,686
		KBI	lagresi22	1	0,071	0,073	0,970	0,335
		Tasikmalaya	w22	1	0,004	0,026	0,150	0,882
		KBI	lagresi32	1	0,274	0,077	3,540	0,001
		Cirebon	w32	1	-0,122	0,055	-2,220	0,028

Tabel F Estimasi parameter GSTARX-SVR data *outflow* dan *inflow*

Studi Skenario	Bobot GSTAR	KBI Bandung					KBI Tasikmalaya					KBI Cirebon				
		Epsilon	Cost	Sigma	MAPE	MAPEp	Epsilon	Cost	Sigma	MAPE	MAPEp	Epsilon	Cost	Sigma	MAPE	MAPEp
<i>Outflow</i>	Seragam	0,00005	350	0,1	16,47676	71,36869	0,00007	352,7	0,05	0,68793	38,36919	0,00008	350	0,05	0,00098	56,75073
		0,00006	350	0,1	16,47676	71,36869	0,00009	354,2	0,05	0,68684	38,3692	0,00008	350,1	0,05	0,00098	56,75073
		0,00007	350	0,1	16,47676	71,36869	0,00007	354,2	0,05	0,68683	38,3692	0,00008	350,2	0,05	0,00098	56,75073
		0,00008	350	0,1	16,47676	71,36869	0,00006	354,2	0,05	0,68684	38,3692	0,00008	350,3	0,05	0,00098	56,75073
		0,00009	350	0,1	16,47676	71,36869	0,00009	353	0,09	0,25185	38,3692	0,00008	350,4	0,05	0,00098	56,75073
	Invers Jarak	0,00009	354,3	0,09	16,90732	71,82363	0,00007	350,2	0,07	0,29129	38,36919	0,00009	352,8	0,05	0,03707	56,75073
		0,00006	350,8	0,1	17,05177	71,82363	0,00006	351,5	0,09	0,00065	38,3692	0,00008	352,8	0,05	0,03708	56,75073
		0,00008	352,1	0,06	18,17062	71,82363	0,00006	351,4	0,09	0,00115	38,3692	0,00007	352,8	0,05	0,03706	56,75073
		0,00009	352,2	0,05	18,81443	71,82363	0,00008	350,5	0,1	0,00061	38,3692	0,00006	352,8	0,05	0,03706	56,75073
		0,00009	353,2	0,08	17,25936	71,82363	0,00005	350,6	0,07	0,29069	38,3692	0,00005	352,8	0,05	0,03696	56,75073
	NIKSP	0,00009	353,20	0,08	19,73099	71,82363	0,00009	354,60	0,09	0,23325	38,36919	0,00008	350,00	0,05	0,00098	56,75073
		0,00007	350,00	0,10	19,12998	71,82363	0,00007	354,60	0,09	0,23326	38,36920	0,00008	350,10	0,05	0,00098	56,75073
		0,00006	351,40	0,05	21,63961	71,82363	0,00005	354,60	0,09	0,23327	38,36920	0,00008	350,20	0,05	0,00098	56,75073
		0,00007	350,70	0,10	19,06739	71,82363	0,00009	350,80	0,09	0,24807	38,36920	0,00008	350,30	0,05	0,00098	56,75073
		0,00007	350,00	0,07	20,57855	71,82363	0,00009	350,00	0,05	0,73913	38,36920	0,00008	350,40	0,05	0,00098	56,75073
<i>Inflow</i>	Seragam	0,00005	355,00	0,05	15,34631	33,39824	0,00005	350,00	0,05	0,00007	28,51198	0,00007	353,40	0,09	1,93793	22,29139
		0,00006	355,00	0,05	15,34631	33,39824	0,00006	350,00	0,05	0,00006	28,51198	0,00006	353,60	0,10	1,92773	22,29139
		0,00007	355,00	0,05	15,34631	33,39824	0,00007	350,00	0,05	0,00006	28,51198	0,00008	354,30	0,09	1,92930	22,29139
		0,00008	355,00	0,05	15,34631	33,39824	0,00008	350,00	0,05	0,00007	28,51198	0,00007	353,60	0,10	1,92774	22,29139
		0,00009	355,00	0,05	15,34631	33,39824	0,00009	350,00	0,05	0,00007	28,51198	0,00005	350,30	0,07	1,98340	22,29139
	Invers Jarak	0,00005	355,00	0,05	15,36375	33,39590	0,00006	350,00	0,05	0,00008	28,51246	0,00005	355,00	0,05	1,93234	22,29139
		0,00006	355,00	0,05	15,36375	33,39590	0,00005	350,00	0,05	0,00008	28,51246	0,00006	353,00	0,06	1,93748	22,29139
		0,00007	355,00	0,05	15,36375	33,39590	0,00007	350,00	0,05	0,00008	28,51246	0,00006	350,60	0,05	1,97449	22,29139

Studi Skenario	Bobot GSTAR	KBI Bandung					KBI Tasikmalaya					KBI Cirebon				
		Epsilon	Cost	Sigma	MAPE	MAPEp	Epsilon	Cost	Sigma	MAPE	MAPEp	Epsilon	Cost	Sigma	MAPE	MAPEp
		0,00008	355,00	0,05	15,36375	33,39590	0,00009	350,00	0,05	0,00008	28,51246	0,00005	351,10	0,07	1,94035	22,29139
		0,00009	355,00	0,05	15,36375	33,39590	0,00008	350,00	0,05	0,00008	28,51246	0,00005	350,80	0,10	1,89961	22,29139

Tabel G Kebaikan model data *outflow* dan *inflow*

Studi Skenario	Metode Peramalan	Bobot	RMSE						MAPE					
			<i>Training</i>			<i>Testing</i>			<i>Training</i>			<i>Testing</i>		
			Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3	Y1	Y2	Y3
<i>Outflow</i>	TSR		483,937	79,767	115,984	976,347	142,750	217,086	76,388	275,973	279,082	48,197	22,102	46,615
	VARX		475,732	79,757	111,963	970,699	142,807	216,269	80,139	268,626	278,539	47,600	22,144	46,289
	VARX-SVR		265,014	0,000	0,000	1568,172	225,055	329,370	16,406	0,001	0,001	71,824	38,369	56,751
	GSTARX	Seragam	484,241	81,423	115,220	977,058	143,922	219,386	76,796	257,488	263,545	48,268	22,791	47,525
		Invers Jarak	484,093	81,388	115,104	976,958	143,905	219,351	76,835	257,624	263,683	48,258	22,782	47,511
		NIKSP	482,032	81,007	115,212	975,185	143,237	218,983	76,602	260,493	265,557	48,078	22,398	47,368
	GSTARX-SVR	Seragam	263,326	4,077	0,000	1568,172	225,055	329,370	19,731	0,688	0,001	71,824	38,369	56,751
		Invers Jarak	262,163	1,724	3,135	1568,172	225,055	329,370	16,907	0,291	0,037	71,824	38,369	56,751
		NIKSP	263,326	1,497	0,000	1568,172	225,055	329,370	19,731	0,233	0,001	71,824	38,369	56,751
<i>Inflow</i>	TSR		619,381	100,374	180,884	1333,284	276,788	314,865	39,831	21,285	19,314	29,266	49,956	25,521
	VARX		616,201	100,383	177,946	1331,306	277,383	314,963	41,905	21,462	18,776	29,133	50,098	25,587
	VARX-SVR		411,209	0,000	45,656	1902,315	223,503	336,705	15,253	0,000	1,491	33,404	28,514	22,291
	GSTARX	Seragam	617,876	100,390	177,967	1331,769	277,400	314,995	41,081	21,451	18,779	29,156	50,103	25,591
		Invers Jarak	617,832	100,389	177,963	1331,807	277,402	315,008	41,072	21,442	18,766	29,159	50,104	25,594
	GSTARX-SVR	Seragam	413,372	0,000	52,234	1902,182	223,501	336,705	15,346	0,000	1,938	33,398	28,512	22,291
		Invers Jarak	415,946	0,000	52,006	1902,129	223,501	336,705	15,364	0,000	1,932	33,396	28,512	22,291

- : Model terbaik untuk data *inflow* atau *outflow*
 : Model dengan bobot terbaik diantara pemodelan GSTARX
 : Model dengan bobot terbaik diantara pemodelan GSTARX-SVR

Tabel H Peramalan data *out sample* studi terapan *outflow* dan *inflow* (dalam milyar)

Lokasi	Bulan	<i>Outflow</i>									<i>Outflow</i>						
		Akt	VARX	VARX-SVR	GSTARX			GSTARX-SVR			Akt	VARX	VARX-SVR	GSTARX		GSTARX-SVR	
					Srgm	Inv. Jrk	NIKSP	Srgm	Inv. Jrk	NIKSP				Srgm	Inv. Jrk	Srgm	Inv. Jrk
1	Jan	1210	1944	1944	2029	2028	2006	1944	1944	1944	5778	5440	4325	5437	5435	4325	4325
	Feb	1502	2047	1250	2060	2060	2057	1250	1250	1250	4559	4668	5085	4672	4672	5085	5085
	Mar	1995	2394	1837	2395	2395	2394	1837	1837	1837	3723	4920	4800	4924	4924	4800	4800
	Apr	1332	2491	2091	2491	2491	2491	2091	2091	2091	4113	4800	3600	4801	4801	3600	3600
	Mei	2204	2494	1336	2494	2494	2494	1336	1336	1336	3646	4912	4224	4912	4912	4224	4224
	Jun	1799	2828	2538	2828	2828	2828	2538	2538	2538	4740	4851	3586	4851	4851	3586	3586
	Jul	7380	5350	4321	5350	5350	5350	4321	4321	4321	2256	5269	5158	5269	5269	5158	5158
	Agust	837	2613	4642	2613	2613	2613	4642	4642	4642	9575	7800	4787	7800	7800	4787	4787
	Sep	1837	2338	562	2338	2338	2338	562	562	562	5237	5510	7284	5510	5510	7284	7284
	Okt	2859	2377	1876	2377	2377	2377	1876	1876	1876	4851	5473	5200	5473	5473	5200	5200
	Nop	2237	2417	2899	2417	2417	2417	2899	2899	2899	4100	5514	4892	5514	5514	4892	4892
	Des	3896	3697	3516	3697	3697	3697	3516	3516	3516	3367	5082	4659	5082	5082	4657	4656
2	Jan	249	337	378	350	350	343	378	378	378	898	765	569	765	765	569	569
	Feb	205	344	258	348	348	345	258	258	258	593	716	832	716	716	832	832
	Mar	267	353	214	354	354	353	214	214	214	539	765	642	765	765	642	642
	Apr	355	361	275	362	362	361	275	275	275	511	742	515	742	742	515	515
	Mei	392	370	363	370	370	370	363	363	363	433	767	536	767	767	536	536
	Jun	401	449	471	449	449	449	471	471	471	540	765	431	765	765	431	431
	Jul	1225	799	751	799	799	799	751	751	751	502	859	634	859	859	634	634
	Agust	258	396	822	396	396	396	822	822	822	1399	1346	989	1346	1346	989	989
	Sep	412	404	267	404	404	404	267	267	267	510	878	932	878	878	932	932
	Okt	392	413	420	413	413	413	420	420	420	607	875	507	875	875	507	507

Lokasi	Bulan	Outflow									Outflow						
		Akt	VARX	VARX-SVR	GSTARX			GSTARX-SVR			Akt	VARX	VARX-SVR	GSTARX		GSTARX-SVR	
					Srgm	Inv. Jrk	NIKSP	Srgm	Inv. Jrk	NIKSP				Srgm	Inv. Jrk	Srgm	Inv. Jrk
	Nop	407	422	400	422	422	422	400	400	400	445	873	606	873	873	606	606
	Des	649	572	557	572	572	572	557	557	557	444	765	396	765	765	396	396
3	Jan	254	453	525	479	478	475	525	525	525	1566	1441	1083	1442	1442	1083	1083
	Feb	207	465	265	474	474	473	265	265	265	1111	1272	1374	1273	1274	1374	1374
	Mar	374	555	295	557	557	557	295	295	295	925	1311	1139	1312	1312	1139	1139
	Apr	457	653	472	654	654	654	472	472	472	1047	1340	951	1340	1340	951	951
	Mei	582	576	379	576	576	576	379	379	379	918	1366	1072	1366	1366	1072	1072
	Jun	578	736	742	736	736	736	742	742	742	1063	1370	922	1370	1370	922	922
	Jul	1612	1170	1013	1170	1170	1170	1013	1013	1013	832	1522	1215	1522	1522	1215	1215
	Agust	243	616	1058	616	616	616	1058	1058	1058	2344	2329	1640	2329	2329	1640	1640
	Sep	535	556	184	556	556	556	184	184	184	1163	1454	1469	1454	1454	1469	1469
	Okt	528	599	578	599	599	599	578	578	578	1643	1522	1231	1522	1522	1231	1231
	Nop	478	588	517	588	588	588	517	517	517	1455	1532	1653	1532	1532	1653	1653
	Des	708	792	682	792	792	792	682	682	682	1225	1419	1342	1419	1419	1342	1342

Tabel I Nilai RMSE *out sample* studi terapan *outflow* dan *inflow*

Lokasi	Bulan	VARX	VARX-SVR	GSTARX			GSTARX-SVR			VARX	VARX-SVR	GSTARX		GSTARX-SVR	
				Srgm	Inv. Jrk	NIKSP	Srgm	Inv. Jrk	NIKSP			Srgm	Inv. Jrk	Srgm	Inv. Jrk
1	Jan	733,33	733,02	818,89	817,74	795,21	733,02	733,02	733,02	337,65	1452,96	340,93	342,96	1452,96	1452,96
	Feb	646,10	548,09	700,78	699,98	685,42	548,09	548,09	548,09	250,78	1092,62	253,81	255,20	1092,62	1092,62
	Mar	575,55	456,70	617,01	616,39	605,19	456,70	456,70	456,70	720,53	1087,45	723,65	723,93	1087,45	1087,45
	Apr	764,14	548,07	788,07	787,70	781,09	548,07	548,07	548,07	712,20	976,11	714,72	714,93	976,11	976,11
	Mei	695,70	625,27	716,74	716,42	710,60	625,27	625,27	625,27	852,05	910,52	853,78	853,92	910,52	910,52
	Jun	761,59	645,64	777,68	777,43	772,97	645,64	645,64	645,64	779,14	955,42	780,72	780,85	955,42	955,42
	Jul	1041,89	1301,59	1052,02	1051,87	1049,04	1301,59	1301,59	1301,59	1348,06	1408,96	1348,85	1348,91	1408,96	1408,96
	Agust	1159,29	1814,43	1167,27	1167,15	1164,92	1814,43	1814,43	1814,43	1408,43	2145,22	1409,08	1409,14	2145,22	2145,22
	Sep	1105,68	1762,62	1113,13	1113,01	1110,93	1762,62	1762,62	1762,62	1331,00	2134,58	1331,61	1331,66	2134,58	2134,58
	Okt	1059,94	1700,81	1066,93	1066,82	1064,87	1700,81	1700,81	1700,81	1277,92	2028,05	1278,50	1278,54	2028,05	2028,05
	Nop	1012,08	1633,90	1018,73	1018,63	1016,77	1633,90	1633,90	1633,90	1290,89	1948,36	1291,41	1291,45	1948,36	1948,36
	Des	970,70	1568,17	977,06	976,96	975,19	1568,17	1568,17	1568,17	1331,31	1902,31	1331,77	1331,81	1902,18	1902,13
2	Jan	88,02	129,14	100,71	100,55	94,10	129,14	129,14	129,14	132,78	328,73	132,78	132,75	328,73	328,73
	Feb	116,23	98,63	123,79	123,68	119,35	98,63	98,63	98,63	127,77	287,28	127,82	127,85	287,28	287,28
	Mar	107,08	86,19	112,90	112,81	109,34	86,19	86,19	86,19	167,17	241,92	167,26	167,27	241,92	241,92
	Apr	92,79	84,52	97,83	97,76	94,75	84,52	84,52	84,52	185,20	209,52	185,27	185,28	209,52	209,52
	Mei	83,59	76,69	88,07	88,00	85,33	76,69	76,69	76,69	222,98	192,95	223,03	223,04	192,95	192,95
	Jun	78,75	75,61	82,72	82,66	80,29	75,61	75,61	75,61	223,33	181,64	223,37	223,37	181,64	181,64
	Jul	176,90	192,38	178,44	178,41	177,49	192,38	192,38	192,38	246,94	175,43	246,97	246,97	175,43	175,43
	Agust	172,49	268,63	173,87	173,85	173,02	268,63	268,63	268,63	231,75	219,05	231,78	231,79	219,05	219,05
	Sep	162,64	257,86	163,94	163,92	163,14	257,86	257,86	257,86	250,56	249,72	250,59	250,59	249,72	249,72
	Okt	154,44	244,79	155,68	155,66	154,92	244,79	244,79	244,79	252,30	239,02	252,32	252,32	239,02	239,02

Lokasi	Bulan	VARX	VARX-SVR	GSTARX			GSTARX-SVR			VARX	VARX-SVR	GSTARX		GSTARX-SVR	
				Srgm	Inv. Jrk	NIKSP	Srgm	Inv. Jrk	NIKSP			Srgm	Inv. Jrk	Srgm	Inv. Jrk
	Nop	147,32	233,41	148,50	148,48	147,78	233,41	233,41	233,41	273,02	233,00	273,04	273,04	233,00	233,00
	Des	142,81	225,05	143,92	143,90	143,24	225,05	225,05	225,05	277,38	223,50	277,40	277,40	223,50	223,50
3	Jan	199,27	271,07	224,89	224,65	221,05	271,07	271,07	271,07	125,38	483,49	124,59	124,55	483,49	483,49
	Feb	230,54	195,93	246,53	246,37	244,42	195,93	195,93	195,93	144,73	389,30	144,92	145,05	389,30	389,30
	Mar	215,24	166,46	227,34	227,21	225,78	166,46	166,46	166,46	252,59	341,17	252,83	252,89	341,17	341,17
	Apr	210,71	144,35	220,16	220,06	218,96	144,35	144,35	144,35	263,40	299,29	263,54	263,59	299,29	299,29
	Mei	188,48	157,70	196,94	196,84	195,86	157,70	157,70	157,70	309,19	276,39	309,27	309,31	276,39	276,39
	Jun	183,73	158,68	190,98	190,90	190,05	158,68	158,68	158,68	308,78	258,80	308,85	308,88	258,80	258,80
	Jul	238,34	270,07	243,18	243,12	242,55	270,07	270,07	270,07	386,78	279,84	386,83	386,84	279,84	279,84
	Agust	258,96	383,02	262,86	262,82	262,36	383,02	383,02	383,02	361,84	361,33	361,88	361,90	361,33	361,33
	Sep	244,25	379,63	247,93	247,89	247,46	379,63	379,63	379,63	354,66	355,61	354,70	354,71	355,61	355,61
	Okt	232,80	360,49	236,28	236,24	235,83	360,49	360,49	360,49	338,62	361,60	338,65	338,67	361,60	361,60
	Nop	224,46	343,92	227,74	227,70	227,31	343,92	343,92	343,92	323,70	349,89	323,73	323,75	349,89	349,89
	Des	216,27	329,37	219,39	219,35	218,98	329,37	329,37	329,37	314,96	336,71	314,99	315,01	336,71	336,71

Tabel J Peramalan hingga 2018

Data	<i>Outflow</i>			<i>Inflow</i>		
	Bandung	Tasikmalaya	Cirebon	Bandung	Tasikmalaya	Cirebon
Jan-15	2117,696	436,840	443,084	5926,256	731,5016	1578,811
Feb-15	2228,901	445,753	474,505	5040,643	648,5618	1315,693
Mar-15	2569,731	454,038	572,728	5215,779	690,3896	1318,243
Apr-15	2567,585	462,757	662,092	5123,762	663,8854	1346,078
Mei-15	2632,376	471,568	600,114	5177,252	677,3173	1353,927
Jun-15	2946,599	555,173	756,214	6012,644	680,4185	1365,738
Jul-15	5851,771	854,403	1341,819	5366,549	759,5591	1481,939
Agust-15	2659,521	498,113	613,332	6037,328	795,0234	1510,016
Sep-15	2477,074	506,968	577,902	5766,620	764,1701	1438,326
Okt-15	2509,786	515,824	604,425	5733,296	768,8098	1541,522
Nop-15	2542,494	524,680	596,818	5645,290	745,8260	1529,275
Des-15	3893,269	689,755	810,135	5182,052	645,6647	1401,447
Jan-16	2607,904	542,392	579,446	6614,307	818,9411	1673,708
Feb-16	2640,609	551,248	581,611	5866,134	729,6998	1455,969
Mar-16	2968,796	560,104	670,354	6005,743	765,5785	1463,220
Apr-16	2962,289	568,961	756,211	5913,398	737,8188	1494,600
Mei-16	3025,621	577,817	692,974	5964,711	750,7233	1503,498
Jun-16	3339,333	661,437	848,625	5988,357	753,6570	1515,747
Jul-16	3658,522	704,735	836,805	8397,909	1131,3280	2284,139
Agust-16	5274,538	921,541	1381,796	6823,937	868,1781	1660,245
Sep-16	2869,541	613,241	670,074	6553,195	837,3168	1588,578
Okt-16	2902,245	622,097	696,590	6519,858	841,9537	1691,783
Nop-16	2934,950	630,953	688,981	6431,847	818,9689	1679,540
Des-16	4285,724	796,028	902,296	5968,607	718,8072	1551,712

Data	<i>Outflow</i>			<i>Inflow</i>		
	Bandung	Tasikmalaya	Cirebon	Bandung	Tasikmalaya	Cirebon
Jan-17	3000,359	648,665	671,608	7400,862	892,0835	1823,974
Feb-17	3033,064	657,521	673,772	6652,689	802,8421	1606,235
Mar-17	3361,250	666,377	762,515	6792,297	838,7207	1613,486
Apr-17	3354,744	675,233	848,372	6699,952	810,9610	1644,866
Mei-17	3418,075	684,089	785,135	9508,299	1350,1667	2511,220
Jun-17	6697,876	1160,901	1551,882	6774,912	826,7992	1666,014
Jul-17	4050,976	811,008	928,967	6939,798	905,8779	1782,374
Agust-17	3444,466	710,658	797,685	7610,491	941,3204	1810,512
Sep-17	3261,995	719,514	762,235	7339,749	910,4591	1738,844
Okt-17	3294,700	728,370	788,751	7306,413	915,0960	1842,050
Nop-17	3327,404	737,226	781,142	7218,402	892,1112	1829,806
Des-17	4678,179	902,301	994,457	6755,162	791,9494	1701,979
Jan-18	3392,814	754,938	763,769	8187,416	965,2257	1974,241
Feb-18	3425,518	763,794	765,933	7439,243	875,9843	1756,502
Mar-18	3753,705	772,650	854,676	7578,852	911,8630	1763,753
Apr-18	3747,198	781,506	940,533	7486,507	884,1033	1795,133
Mei-18	3810,530	790,362	877,296	8349,046	897,0078	1804,031
Jun-18	6710,045	1129,921	1630,210	7561,466	899,9415	1816,280
Jul-18	4443,431	917,281	1021,128	7726,352	979,0202	1932,640
Agust-18	3836,920	816,931	889,846	8397,046	1014,4626	1960,778
Sep-18	3654,450	825,787	854,396	8126,304	983,6013	1889,111
Okt-18	3687,155	834,643	880,912	8092,967	988,2382	1992,316
Nop-18	3719,859	843,499	873,303	8004,956	965,2534	1980,073
Des-18	5070,634	1008,574	1086,618	7541,716	865,0917	1852,245

SURAT PERNYATAAN

Saya yang bertanda tangan di bawah ini, mahasiswa Departemen Statistika FMKSD ITS:

Nama : Bahagiati Maghfiroh

NRP : 06211650010022

Program Studi : Magister Statistika

menyatakan bahwa data yang digunakan dalam Tesis ini merupakan data sekunder yang diambil dari publikasi BI yaitu:

Sumber : Bank Indonesia, DKI Jakarta

Keterangan : KPw II Provinsi Jawa Barat

Surat pernyataan ini dibuat dengan sebenarnya. Apabila terdapat pemalsuan data maka saya siap menerima sanksi sesuai aturan yang berlaku.

Surabaya, 31 Januari 2018

Mengetahui :

Pembimbing Tesis

Mahasiswa

Dr. Santi Puteri Rahayu, M.Si

NIP. 19750115 199903 2 003

Bahagiati Maghfiroh

NRP. 06211650010022

BIODATA PENULIS



Bahagiati Maghfiroh, nama penuh doa yang diharapkan penulis dapat membahagiakan orang-orang di sekitarnya sehingga kebahagiaan itu akan kembali kepadanya. Penulis dilahirkan pada 17 Juni 1994 di Lamongan. Merupakan anak kedua dari tiga bersaudara, satu-satunya anak perempuan dari pasangan Kasnan dan Tisah. Pendidikan formal yang ditempuh, yaitu TK Mekar Mulya, SDN Sidomulyo II Deket Lamongan, SMPN 1 Lamongan, SMAN 2 Lamongan.

Setelah lulus SMA, penulis mengikuti SNMPTN Tulis dan diterima di Jurusan Statistika ITS (2012). Setelah menempuh pendidikan Sarjana selama 3,5 tahun, penulis melanjutkan ke jenjang Magister Statistika ITS (2016) dengan Beasiswa *Fresh Graduate*. Sembari kuliah Pascasarjana, penulis bekerja di Badan Penelitian dan Pengembangan Kesehatan, Kementerian Kesehatan RI. Penulis memiliki motto “*Bismillah*”, apapun yang diinginkan, dicita-citakan dan dimimpikan, Insyaallah dengan izin-Nya semua dapat diwujudkan. Apabila ingin berdiskusi dengan penulis, pembaca dapat menghubungi melalui bahagia.ti@gmail.com.